

Método de Reducción de Incertidumbre Basado en Algoritmos Evolutivos y Paralelismo Orientado a la Predicción y Prevención de Desastres Naturales

Doctorado en Ciencias de la Computación,
Facultad de Ciencias Físico Matemáticas y Naturales de la Universidad Nacional
de San Luis

Autor: Miguel Méndez-Garabetti

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

Fecha de defensa: 20 de julio de 2020.

Director:

Dr. Bianchini Germán

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

gbianchini@frm.utn.edu.ar

Codirectora:

Dra. Verónica Gil Costa

Laboratorio de Investigación y Desarrollo Científico (LIDIC), Departamento de Informática, Facultad de Ciencias Físico Matemáticas y Naturales, Universidad Nacional de San Luis, Argentina.

ggvcosta@gmail.com

Codirectora Beca Doctoral CONICET:

Dra. Caymes-Scutari Paola

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

pcaymesscutari@frm.utn.edu.ar

Resumen

La presente tesis doctoral aborda la problemática de la incertidumbre existente en todo sistema de predicción, focalizando en el desarrollo de métodos de reducción de incertidumbre aplicados a la predicción de fenómenos naturales. Debido a que estos fenómenos suelen causar gran impacto en las comunidades, la flora y la fauna, el ecosistema, entre otros, los sistemas de predicción deben proporcionar respuesta en el menor tiempo posible. Por estos motivos, los métodos propuestos han sido desarrollados utilizando capacidades de alto rendimiento. El primer método desarrollado en esta tesis (ESS-IM), comenzó con el objetivo de lograr una mejora a una metodología previamente desarrollada denominada ESS (Sistema Estadístico Evolutivo). Específicamente se trabajó en el incremento del paralelismo de la metaheurística interna, incorporando una arquitectura basada en modelo de islas bajo un esquema de migración. Este desarrollo logró incrementar la capacidad de búsqueda de la metaheurística interna, impactando de forma directa en un incremento en la calidad de predicción del método. En la validación, ESS-IM fue aplicado en una serie de casos de quemas controladas e incendios forestales. Es importante destacar que, en forma conjunta al desarrollo de la tesis, se llevaron a cabo diferentes investigaciones complementarias, tales como: estudios de sintonización de parámetros, desarrollo de un sistema de generación de mapas de incendios forestales a partir de imágenes satelitales, diseño de una red inalámbrica de sensores como sistema de alerta temprana, entre otros. Finalmente, en la última etapa de la tesis, se implementó una versión híbrida basada en metaheurísticas evolutivas bajo una estrategia colaborativa

basada en islas. El método HESS-IM, se implementó de forma heterogénea (a nivel de hardware), logrando que los resultados obtenidos incrementen la calidad de predicción y eficiencia del método.

Palabras clave: reducción de incertidumbre, paralelismo, computación de alto rendimiento, metaheurísticas evolutivas híbridas poblacionales.

1. Introducción

Los modelos se han convertido en uno de los principales instrumentos de la ciencia moderna, éstos suelen utilizarse en la representación de gran cantidad de sistemas físicos (Stanford University & Center for the Study of Language and Information (U.S.), 1997), inclusive en el ámbito de la ciencia ambiental para efectuar predicciones. La modelización puede ser vista como el establecimiento de relaciones semánticas entre la teoría y los fenómenos u objetos. Generalmente, los modelos representan alguna situación real, pero de manera incompleta e inexacta; esto permite realizar estudios de sistemas complejos de forma aproximada. Usualmente, los modelos deben ser alimentados con parámetros de entrada, los cuales brindan la información necesaria con la cual es posible determinar las condiciones iniciales del fenómeno bajo estudio, y de esta manera estimar sus posibles variaciones en el tiempo. Esto se conoce como “salida del modelo”, la cual representa la evolución del sistema a lo largo del tiempo.

Cuando se lleva a cabo el estudio de un fenómeno complejo mediante la simplificación de la realidad, usando modelos, éstos pueden verse afectados debido a la calidad de la información con que dicho modelo es alimentado. Es decir, el mero hecho de simplificar un fenómeno físico para poder representarlo mediante un modelo implica pérdida de precisión, exactitud y certeza, respecto del comportamiento real del fenómeno. Si junto a esto se considera que dicho modelo “simplificado” es alimentado con información incompleta o de baja calidad, evidentemente tendremos resultados no del todo satisfactorios y distantes de la realidad.

Esta problemática, que surge a partir de la falta de precisión o exactitud en los parámetros de entrada de un modelo, se conoce como incertidumbre. Como bien se menciona en (Ishigami & Homma, 1990): “cuando se analizan sistemas complejos, los resultados calculados incluyen incertidumbres debidas a los propios modelos informáticos, como así también a las existentes en los valores de las variables de entrada o los parámetros utilizados en el análisis. Debido a esto, es importante no solo cuantificar las incertidumbres de salida sino también identificar las variables de entrada dominantes que contribuyen a las incertidumbres de salida”.

1.1. Motivación

En base a esto, se puede decir que en cualquier ámbito donde se realice algún tipo de predicción existirá mayor o menor grado de incertidumbre (tanto se trate de un modelo económico, meteorológico o natural) y con ello el esfuerzo por intentar minimizar sus efectos negativos. Dicho en otras palabras, ante la presencia de incertidumbre (principal fuente de imprecisión en todo sistema de predicción), es necesario intentar eliminarla, o en el mejor de los casos lograr reducirla. En la literatura se utiliza el término Reducción de Incertidumbre o Métodos de Reducción de Incertidumbre para hacer referencia a aquellas técnicas o herramientas que de alguna manera permiten reducir los efectos causados por la falta de precisión en cualquier variable o factor de un sistema de predicción. El concepto de Método de Reducción de Incertidumbre (MRI o Uncertainty Reduction Method, URM) ha sido acuñado en el trabajo de Ishigami y Homma en 1990 (Ishigami & Homma, 1990).

El concepto de MRI se utiliza en diversas áreas de la ciencia, algunos ejemplos son (Bartezzaghi, Verganti, & Zotteri, 1999; Hu, Mahadevan, & Ao, 2018; Kalyuzhnaya & Boukhanovsky, 2015; Li, Hamel, & Azarm, 2010; Purica & Bae, 2016; Qian, Li, & Yang, 2013; Sano, Takeda, & Yamasaki, 2009; Taghribi & Sharifian, 2017). En el contexto de la presente tesis se ha definido un MRI de la siguiente manera: “sistema computacional cuyo objetivo consiste en mejorar la calidad de salida de un modelo determinado, de forma independiente a los datos con que éste haya sido alimentado”. Esto se logra mediante algún tipo de pre-procesamiento y/o pos-procesamiento de los datos de entrada y/o salida del modelo. Las funciones llevadas a cabo por un MRI no deben interferir con las operaciones internas del modelo bajo análisis, es decir, este último debe ser tratado como una caja negra. En este sentido podemos mencionar que la reducción de incertidumbre corresponde al proceso que permite minimizar los efectos negativos causados por la falta de precisión en las variables de entrada de un modelo determinado, permitiendo optimizar el funcionamiento de éste e impactando de forma positiva en la calidad de la salida del mismo. La reducción de incertidumbre puede lograrse de diferentes maneras en función del fenómeno con el que se esté tratando, el modelo utilizado, la implementación realizada, etc. Por ejemplo, en la predicción meteorológica, la reducción de incertidumbre puede llevarse a cabo mediante la medición de variables atmosféricas en tiempo real (Doeswijk, 2007; Farguell et al., 2016).

En esta tesis se abordó el desarrollo de métodos generales de reducción de incertidumbre que puedan ser aplicados en la predicción de diferentes fenómenos naturales. Puntualmente se utilizó como caso de estudio a los incendios forestales dado que para este tipo de fenómenos ha sido factible conseguir datos de casos de quemas, y además desde el contexto local, éste es uno de los fenómenos naturales que ocurren con mayor frecuencia.

2. La problemática de los incendios forestales

Cuando se habla de incendios forestales, comúnmente se connota con los aspectos negativos que éstos poseen. Sin embargo, éstos juegan un rol fundamental en los cambios naturales que ocurren en los ecosistemas de nuestro planeta. Los efectos del fuego, sobre bosques, praderas, etc., propician la diversidad de la vida vegetal y animal. Incluso ciertos tipos de plantas no tienen posibilidad de reproducirse sin el fuego. El fuego inicia procesos naturales que permiten convertir la materia orgánica en nutrientes que posteriormente la lluvia entrega al suelo, proporcionando un semillero fértil rejuvenecido para las plantas (Graham, 1999). Sin embargo, los incendios forestales fuera de control suelen generar grandes pérdidas y daños, destacándose entre ellos: pérdidas de vidas humanas, daños a la flora, la fauna y al suelo (Morgan et al., 2001). Las pérdidas económicas son difíciles de estimar debido a la gran cantidad de sectores que pueden verse afectados a corto, mediano o largo plazo, pero en general los recursos ambientales de toda zona afectada suelen ser considerablemente damnificados.

Los incendios forestales afectan millones de hectáreas año tras año haciendo de estos fenómenos uno de los principales agentes de perturbación de los ecosistemas del planeta. En Argentina, según el último informe publicado por el Ministerio de Ambiente y Desarrollo Sustentable de la Presidencia de la Nación Argentina, año 2016 (*Estadísticas de Incendios Forestales 2016*, 2016), durante 2016 se consumieron 1.072.642 hectáreas. De este total un 54,74% corresponde a superficie de pastizal, un 28,04% de arbustal, un 16,47% de bosque nativo y el resto corresponde a bosque cultivado y superficie sin determinar. Además, los incendios forestales ocurren con mayor frecuencia en época

estival, donde se incrementa la sequedad, las temperaturas y/o el viento, lo que en conjunto facilita la propagación del fuego destruyendo así extensas superficies.

Debido a las pérdidas y daños que pueden producir, desde diferentes áreas de la ciencia se trabaja constantemente en el desarrollo de herramientas, sistemas, estrategias, etc., que permitan reducir los efectos negativos que éstos ocasionan. Entre estos se pueden encontrar: estrategias de evacuación, tecnologías para la extinción del fuego, cortafuegos, modelos de comportamiento, simuladores de incendios, sistemas de predicción, entre otros. Estas herramientas suelen utilizarse en distintas etapas del proceso de incendios forestales: prevención, predicción, detección y monitorización.

3. Predicción de comportamiento de incendios forestales

Tal como se mencionó previamente, en el contexto de esta tesis, se ha trabajado en el desarrollo de MRI aplicados a la predicción del comportamiento de los incendios forestales. Es decir, el proceso que consiste en intentar pronosticar el comportamiento de la propagación de un incendio forestal ya iniciado, con el objetivo de conocer las zonas que presentan mayor riesgo de ser alcanzadas por el fuego y tomar decisiones o medidas de acuerdo a ello. La simulación de la propagación de incendios forestales es una tarea difícil desde el punto de vista computacional, tanto por la complejidad involucrada en los modelos utilizados, como así también por la incertidumbre que afecta a este proceso. Más allá de la imprevisibilidad del comportamiento de los incendios forestales, la incertidumbre proviene de diferentes fuentes tales como: datos inexactos y/o faltantes, comprensión científica incompleta de la respuesta ecológica al fuego y de la respuesta del comportamiento del fuego a los tratamientos de mitigación, entre otros (Thompson & Calkin, 2011).

El concepto general de predicción del comportamiento de incendios forestales consiste en un simulador de incendios (basado en algún modelo de comportamiento de incendios forestales), tratado como una caja negra, alimentado con ciertos parámetros de entrada (**PE**) que representan condiciones actuales del incendio, tales como: velocidad y dirección del viento, vegetación, características de la superficie, entre otros. El simulador necesita, además de los **PE**, la Línea de Fuego Real (**LFR**) del incendio en el instante de tiempo t_n (**LFR_n**). Una vez que el simulador es ejecutado, éste genera en su salida la predicción de la línea de fuego o Línea de Fuego Predicha (**LFP**) para el instante de tiempo posterior, t_{n+1} . Por supuesto, se espera que dicha predicción tenga un alto grado de coincidencia con el estado real del incendio para dicho instante de tiempo (**LFR_{n+1}**) de la mejor manera posible. Este enfoque también es conocido como predicción de un paso adelante (Nowak, 2002). Sin embargo, debido a la complejidad e incertidumbre del modelo de comportamiento del fuego, la incertidumbre en los parámetros de entrada, y a que la predicción está basada en una única simulación, esta metodología no suele ofrecer una predicción lo suficientemente aproximada a la realidad como para ser considerada una herramienta confiable para la toma de decisiones. Algunos ejemplos de predicción clásica son (Andrews et al., 2008; DX, PR, & L, 1998; Finney, 1998; Heinsch & Andrews, 2010; Lopes, Cruz, & Viegas, 2002; Wallace, 1993). Las limitaciones presentes en el enfoque de predicción clásica han hecho evidente la necesidad de incorporar técnicas de reducción de incertidumbre que permitan mejorar el rendimiento (en calidad y tiempo de respuesta) de los sistemas de predicción actuales. En este contexto, los desarrollos de los MRI cobran vital importancia ya que han demostrado, tras ser aplicados en diferentes áreas de la ciencia, efectividad a la hora de minimizar los efectos negativos causados por las diferentes incertidumbres permitiendo mejorar la calidad de salida de los modelos tratados. Además, debido a que estos sistemas suelen trabajar con grandes conjuntos de

datos sobre los cuales es necesario realizar complejas operaciones, éstos sistemas suelen requerir de sistemas de computación de alto rendimiento (Buyya, 1999), los cuales permiten reducir el tiempo de procesamiento al utilizar múltiples unidades de cómputo en simultáneo.

4. Contribuciones de la tesis

La presente tesis contribuye al desarrollo de métodos de reducción de incertidumbre capaces de asistir y participar en el proceso de resolución de problemas de alta magnitud y complejidad computacional, tal como la predicción y prevención de desastres naturales. Este tipo de problemas puede ser clasificado en la categoría de Grand Challenge Problems (Wilkinson & Allen, 1999), es decir, problemas de alta complejidad, y a la vez importantes (desde el punto de vista social y económico) donde se requieren varios órdenes de magnitud de recursos para resolverlos.

Los métodos desarrollados, si bien han sido concebidos como generales (ya que podrían ser aplicados a diferentes fenómenos naturales con características de propagación), fueron validados tras su aplicación en la predicción del comportamiento de incendios forestales. Los métodos desarrollados pertenecen a la categoría de Métodos Guiados por Datos con Solución Múltiple Solapada (DDM-MOS, Data Driven Methods with Multiple Overlapping Solutions) (Germán. Bianchini, 2006), a la cual también pertenecen los métodos: S²F²M (Germán Bianchini, Denham, Cortés, Margalef, & Luque, 2010), ESS (G. Bianchini, Caymes-Scutari, & Méndez-Garabetti, 2015) y ESSIM-DE (Tardivo, Caymes-Scutari, Méndez-Garabetti, & Bianchini, 2018). Es importante resaltar que esta tesis ha permitido incrementar dos de las características principales de este tipo de metodologías, a saber: a) la calidad de predicción, y b) el tiempo de respuesta, esto mediante la utilización de metaheurísticas híbridas paralelas (Alba, Luque, & Nesmachnow, 2013) en conjunto con técnicas de análisis estadístico y computación de alto rendimiento.

Métodos desarrollados:

- ESS-IM (M. Méndez-Garabetti, Bianchini, Caymes-Scutari, & Tardivo, 2016): Desarrollo del método de reducción de incertidumbre denominado Sistema Estadístico Evolutivo con Modelo de Islas (Evolutionary Statistical System with Island Model, ESS-IM). Este método ha sido aplicado a la predicción del comportamiento de incendios forestales, logrando incrementar considerablemente la calidad de predicción, respecto de metodologías previas. Dicha mejora es lograda mediante el incremento del paralelismo de la metaheurística interna.
- HESS-IM (Miguel Méndez-Garabetti, Bianchini, Tardivo, Caymes Scutari, & Gil Costa, 2017): Desarrollo del método de reducción de incertidumbre denominado Sistema Estadístico Híbrido Evolutivo con Modelo de Islas (Hybrid Evolutionary Statistical System with Island Model, ESS-IM). Este desarrollo, también aplicado a la predicción del comportamiento de incendios forestales, ha permitido incrementar tanto la calidad de predicción como el tiempo de respuesta. Esto ha sido posible mediante la utilización de un esquema híbrido a nivel de la técnica de optimización basada en metaheurísticas, y uno heterogéneo a nivel de utilización de hardware. Para ello el método implementa un framework capaz de operar con diferentes metaheurísticas de forma colaborativa (conformando así una metaheurística híbrida) y el paralelismo necesario ha sido implementado basado en una arquitectura heterogénea CPU-GPU.

5. Sistema Estadístico Híbrido Evolutivo con Modelo de Islas (HESS-IM)

HESS-IM es un método general de reducción de incertidumbre que ha sido planteado como un framework adaptativo para la implementación de técnicas de optimización colaborativa basada en diferentes metaheurísticas evolutivas poblacionales. De esta manera, HESS-IM permite vincular n metaheurísticas evolutivas para resolver de forma colaborativa la optimización de soluciones del método de predicción. HESS-IM implementa una metaheurísticas híbrida basada en tres metaheurísticas poblacionales evolutivas: a) Algoritmos Evolutivos, b) Evolución Diferencial y c) Optimización por Cúmulo de Partículas, bajo un esquema de colaboración basado en migraciones. Desde el punto de vista de paralelismo se utiliza MPI conjuntamente con CUDA (David B. Kirk, 2013) para lograr reducir el tiempo de procesamiento.

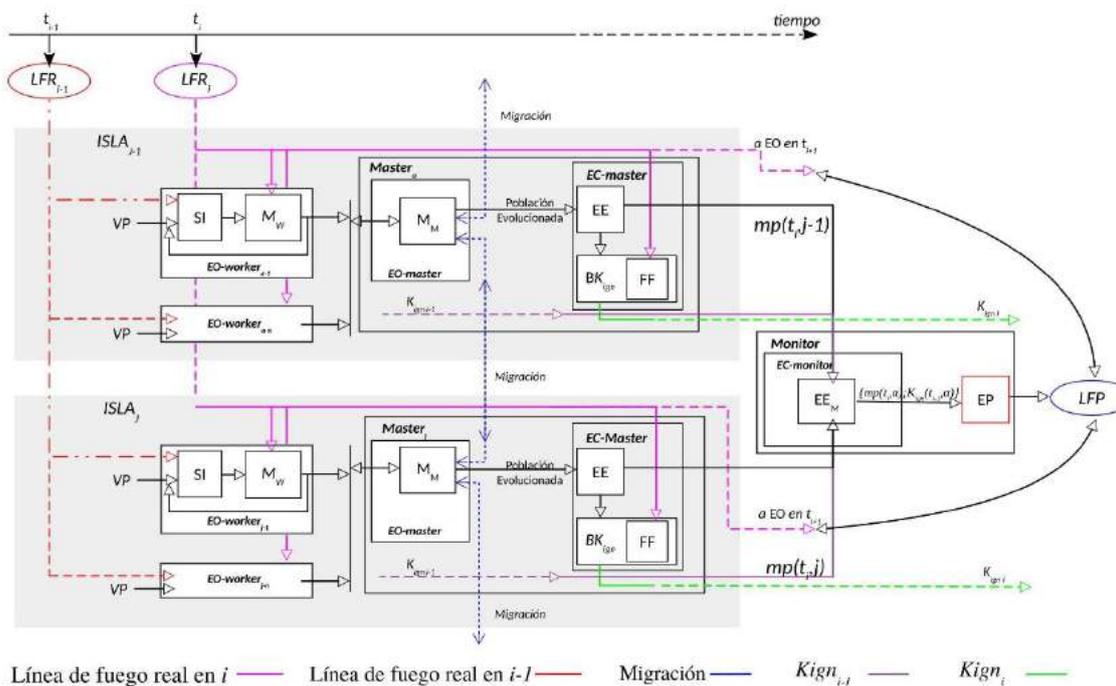


Figura 1 - HESS-IM: Sistema Estadístico Híbrido Evolutivo con Modelo de Islas. SI: simulador de incendios; M_M : etapa metaheurística en master; M_W : etapa metaheurística en worker (evaluación de fitness); EO: etapa de optimización; EE: etapa estadística; BK_{ign} : búsqueda de K_{ign} ; K_{ign} : valor clave de ignición; FF: función de fitness; EC: etapa de calibración; EP: etapa de predicción; LFP: línea de fuego predicha; LFR_x : línea de fuego real en tiempo x ; VP: vector de parámetros de entrada; EEM: etapa estadística en proceso monitor; mp : mapa de probabilidad.

La técnica de optimización de HESS-IM se implementa en un esquema de paralelización basado en islas con doble jerarquía master-worker. Este esquema permite a cada isla operar con una metaheurística diferente sobre el mismo espacio de búsqueda, intercambiando entre sí soluciones candidatas cada cierto intervalo de tiempo, o a demanda de determinados eventos.

Un esquema general del funcionamiento de HESS-IM se observa en la Fig. 1. La cadena de predicción comienza en el proceso Monitor, éste envía a cada una de las n islas dos conjuntos de datos iniciales: a) conjunto de datos del incendio: un mapa con el frente de fuego real, intervalos de tiempo a considerar para cada paso de predicción, valores y rangos para cada parámetro de entrada del modelo, y b) conjunto de datos de las metaheurísticas: cantidad de islas, metaheurística que cada isla deberá utilizar, cantidad

de workers por isla, parámetros de migración, parámetros propios de cada metaheurística, etc.

Dichos conjuntos de datos son recibidos por el proceso master de cada isla, donde se instancia la Etapa de Optimización $\mathbf{EO}_{\text{master}}$, que da inicio a la metaheurística requerida por el proceso monitor, ya sea: EA, DE o PSO. Dicho procesamiento se realiza en la Etapa Metaheurística, la cual se encuentra dividida en dos subetapas: por un lado, la Etapa Metaheurística, del proceso master \mathbf{MM} , y por el otro, la Etapa Metaheurística de los procesos workers \mathbf{MW} . La etapa \mathbf{MM} realiza diferentes operaciones dependiendo del momento en que se encuentre operando el método y en función de la metaheurística configurada en dicha isla. Sin embargo, existen ciertas funciones que todas las islas realizan en común tales como:

1. Inicialización de la población: al inicio del proceso de predicción, esta etapa se encarga de inicializar la población de individuos y de enviar los mismos a los workers para que éstos sean tratados.
2. Migración de individuos: mientras los workers procesan a los individuos, la etapa \mathbf{MM} lleva a cabo la migración de individuos hacia las islas vecinas. La migración se realiza en función de la topología de comunicación y tipo de migración configurada. Esta última puede ser: a) con mayor frecuencia entre islas que operen con la misma metaheurística, o b) con un único valor de frecuencia para todas las islas.
3. Evolución de la población: cuando se alcanza la cantidad máxima de iteraciones o el umbral de aptitud, dentro de cada iteración, se realiza la evolución de la población hacia la próxima generación evolutiva.
4. Finalización y envío: cuando la población ha evolucionado, cumpliendo la condición de finalización, se envía, desde la etapa \mathbf{MM} la población final de individuos hacia la Etapa de Calibración ($\mathbf{EC}_{\text{master}}$).

Por su lado, los workers tienen como función principal evaluar la aptitud de cada individuo mediante la utilización del simulador de comportamiento de incendios forestales (\mathbf{SI}). Dicho simulador está basado en el modelo definido por Rothermel (Rothermel, 1972) e implementado mediante la librería fireLib (Collin D. Bevens, 1996) para CPU y CUDA-FGM (Sousa, dos Reis, & Pereira, 2012) para GPU, la cual corresponde a una implementación de firelib para GPU (Kindratenko, Enos, & Shi, 2009; Tsutsui & Collet, 2013).

El cálculo de la evaluación de aptitud en el instante t_i necesita contar con la línea de fuego real del incendio (\mathbf{LFR}) en t_{i-1} (es decir, \mathbf{LFR}_{i-1}) y los valores de los parámetros de entrada, los cuales se almacenan en los vectores de parámetros (\mathbf{VP}) (los individuos de la población). La función de aptitud utilizada para determinar la calidad de cada individuo está basada en el índice de Jaccard (Real & Vargas, 1996). Esta función permite comparar el mapa simulado con el mapa real en t_i (\mathbf{LFR}_i) y, en función de la diferencia entre los dos mapas, se determina el valor de aptitud para cada individuo. La Etapa de Calibración del proceso master ($\mathbf{EC}_{\text{master}}$) calcula un mapa de probabilidad en función de todos los individuos de la población final. Dicho mapa se utiliza para obtener el valor clave de ignición (Key Ignition Value, \mathbf{K}_{ign}), el cual representa el patrón de comportamiento del incendio y es obtenido en la etapa Búsqueda del \mathbf{K}_{ign} (\mathbf{BK}_{ign}).

Para cada instante de tiempo i , cada isla j genera un $\mathbf{K}_{\text{ign}(t_i, j)}$ y un mapa de probabilidad $\mathbf{mp}(t_i, j)$, los cuales son enviados a la etapa de calibración del proceso monitor ($\mathbf{EC}_{\text{Monitor}}$). El primero es enviado a $\mathbf{EC}_{\text{Monitor}}$ en t_{i+1} y el segundo a $\mathbf{EC}_{\text{Monitor}}$ en t_i . Éstos valores finalmente son ingresados en la etapa de predicción (\mathbf{EP}) la cual realiza el cálculo de predicción (línea de fuego predicha, \mathbf{LFP}) para el próximo instante de tiempo \mathbf{LFR}_{i+1} .

Debido a esto HESS-IM no genera predicción en el primer instante de tiempo, ya que en dicho momento se calcula el primer K_{ign} .

Es importante tener en cuenta que la hibridación tiene en consideración las diferentes velocidades de los algoritmos, con el propósito de que todas las metaheurísticas avancen al mismo tiempo. Se estudiaron configuraciones de cada metaheurística con el objetivo de garantizar dicho fin, aunque de igual manera los intercambios de información entre las islas se realizan de manera asincrónica, evitando de este modo cualquier problema por desacoplamiento de velocidades.

6. Resultados obtenidos

La hibridación implementada en HESS-IM utilizando tres metaheurísticas poblacionales evolutivas ha permitido mejorar el optimizador del método incrementando la calidad de predicción en una serie de 6 casos que quemas controladas y 3 incendios forestales reales. La hibridación se ve mejorada utilizando un esquema de migración basado en topología de anillo entre diferentes metaheurísticas utilizando una configuración de parámetros clásica. La metodología ha sido validada aplicando la misma sobre casos de quemas controladas como así también en casos de incendios forestales. La implementación CPU-GPU del método ha permitido mejorar también el rendimiento del método en términos de tiempo de ejecución, siendo este un factor de suma importancia en los sistemas abocados a resolver problemáticas con gran impacto social.

7. Conclusiones y trabajo futuro

En esta tesis se ha trabajado en el tratamiento de la reducción de incertidumbre en relación a los métodos de predicción y prevención de desastres naturales. Puntualmente se ha abordado como caso de estudio la problemática de los incendios forestales, uno de los más grandes problemas que afecta extensas regiones a lo largo del mundo y de nuestro país. El problema en cuestión ha sido tratado desde diferentes perspectivas. Por un lado, el enfoque principal de esta tesis consistió en el desarrollo de métodos de reducción de incertidumbre que puedan ser utilizados para predecir el comportamiento de este fenómeno. Y, por otro lado, se ha avanzado en otras aristas, como el diseño de un sistema integral de detección, alerta temprana y predicción de incendios forestales, el cual podría brindar asistencia en la lucha y mitigación de incendios, como así también en la prevención de los mismos. Este sistema integra los métodos propuestos, con el uso de redes inalámbricas de sensores y un sistema de generación automática de mapas alimentado por imágenes satelitales. Esta línea de trabajo podría hacer posible que este tipo de metodologías llegasen a ser implementadas y adoptadas por entes gubernamentales, permitiendo de esta manera minimizar los daños causados por este fenómeno (esta línea se encuentra dentro del plan de trabajo futuro).

En la presente tesis se han propuesto y desarrollado dos métodos de reducción de incertidumbre capaces de asistir y participar en el proceso de resolución de problemas de alta magnitud y complejidad computacional, tal como la predicción y prevención de desastres naturales. En este sentido, los métodos desarrollados fueron: a) Sistema Estadístico Evolutivo con Modelo de Islas (ESS-IM)¹, y b) Sistema Estadístico Híbrido Evolutivo con Modelo de Islas (HESS-IM), los cuales han logrado mejoras considerables en relación a la calidad de las predicciones generadas y así también en términos de tiempo de respuesta, inclusive tras su aplicación con incendios forestales de gran escala.

8. Bibliografía

Alba, E., Luque, G., & Nesmachnow, S. (2013). Parallel metaheuristics: recent advances and new trends.

¹ Por motivos de espacio en el presente artículo este método no ha sido descrito detalladamente.

- International Transactions in Operational Research*, 20(1), 1–48. <https://doi.org/10.1111/j.1475-3995.2012.00862.x>
- Andrews, P. L., Bevins, C. D., Seli, R. C., Andrews, A., Bevins, P. L., & Seli, C. D. (2008). BehavePlus fire modeling system, version 4.0: User's Guide Revised.
- Bartezzaghi, E., Verganti, R., & Zotteri, G. (1999). A simulation framework for forecasting uncertain lumpy demand. *International Journal of Production Economics*, 59(1–3), 499–510. [https://doi.org/10.1016/S0925-5273\(98\)00012-7](https://doi.org/10.1016/S0925-5273(98)00012-7)
- Bianchini, G., Caymes-Scutari, P., & Méndez-Garabetti, M. (2015). Evolutionary-Statistical System: A parallel method for improving forest fire spread prediction. *Journal of Computational Science*, 6, 58–66. <https://doi.org/10.1016/J.JOCS.2014.12.001>
- Bianchini, Germán. (2006). *Wildland fire prediction based on statistical analysis of multiple solutions. TDX (Tesis Doctorals en Xarxa)*. Universitat Autònoma de Barcelona.
- Bianchini, Germán, Denham, M., Cortés, A., Margalef, T., & Luque, E. (2010). Wildland fire growth prediction method based on Multiple Overlapping Solution. *Journal of Computational Science*, 1(4), 229–237. <https://doi.org/10.1016/j.jocs.2010.07.005>
- Buyya, R. (1999). *High Performance Cluster Computing: Architectures and Systems*. Prentice Hall, PTR, NJ, USA.
- Collin D. Bevins. (1996). *fireLib User Manual and Technical Reference*.
- David B. Kirk, W. W. H. (2013). *Programming Massively Parallel Processors (2nd). Special Edition*. <https://doi.org/10.1016/B978-0-12-381472-2.00001-5>
- Doeswijk, T. G. (2007). *Reducing Prediction Uncertainty of Weather Controlled Systems*. Wageningen University, The Netherlands.
- DX, V., PR, R., & L, M. (1998). An empirical model for the spread of a fireline inclined in relation to the slope gradient or to wind direction. En *Proceedings of the 3rd international conference on forest fire research. 14th Conference on Fire and Forest Meteorology* (pp. 325–342). Luso, Portugal.
- Estadísticas de Incendios Forestales 2016*. (2016). Buenos Aires: Presidencia de la Nación.
- Farguell, A., Moré, J., Cortés, A., Miró, J. R., Margalef, T., & Altava, V. (2016). Reducing Data Uncertainty in Surface Meteorology Using Data Assimilation: A Comparison Study. *Procedia Computer Science*, 80, 1846–1855. <https://doi.org/10.1016/J.PROCS.2016.05.475>
- Finney, M. A. (1998). FARSITE : Fire Area Simulator — Model Development and Evaluation. *USDA Forest Service Research Paper*, (February), 47. <https://doi.org/U.S.ForestServiceResearchPaperRMRS-RP-4Revised>
- Graham, S. (1999, octubre 22). Global Fire Monitoring. Recuperado 1 de mayo de 2018, de https://earthobservatory.nasa.gov/Features/GlobalFire/fire_2.php
- Heinsch, F. A., & Andrews, P. L. (2010). *BehavePlus fire modeling system, version 5.0: Design and Features. USDA Forest Service - General Technical Report RMRS-GTR*.
- Hu, Z., Mahadevan, S., & Ao, D. (2018). Uncertainty aggregation and reduction in structure–material performance prediction. *Computational Mechanics*, 61(1–2), 237–257. <https://doi.org/10.1007/s00466-017-1448-6>
- Ishigami, T., & Homma, T. (1990). An importance quantification technique in uncertainty analysis for computer models. En *Proceedings of the ISUMA 90', First International Symposium on Uncertainty Modelling and Analysis*, (pp. 398–403). IEEE Comput. Soc. Press. <https://doi.org/10.1109/ISUMA.1990.151285>
- Kalyuzhnaya, A. V., & Boukhanovsky, A. V. (2015). Computational Uncertainty Management for Coastal Flood Prevention System. *Procedia Computer Science*, 51, 2317–2326. <https://doi.org/10.1016/J.PROCS.2015.05.397>
- Kindratenko, V. V., Enos, J. J., & Shi, G. (2009). GPU clusters for high- performance computing. *IEEE International Conference on Cluster Computing and Workshops*, 1–8. <https://doi.org/10.1109/CLUSTER.2009.5289128>
- Li, M., Hamel, J., & Azarm, S. (2010). Optimal uncertainty reduction for multi-disciplinary multi-output systems using sensitivity analysis. *Structural and Multidisciplinary Optimization*, 40(1–6), 77–96. <https://doi.org/10.1007/s00158-009-0372-6>
- Lopes, A. M. G., Cruz, M. G., & Viegas, D. X. (2002). FireStation — an integrated software system for the numerical simulation of fire spread on complex topography. *Environmental Modelling & Software*, 17(3), 269–285. [https://doi.org/10.1016/S1364-8152\(01\)00072-X](https://doi.org/10.1016/S1364-8152(01)00072-X)
- Méndez-Garabetti, M., Bianchini, G., Caymes-Scutari, P., & Tardivo, M. L. (2016). Increase in the quality of the prediction of a computational wildfire behavior method through the improvement of the

- internal metaheuristic. *Fire Safety Journal*, 82, 49–62. <https://doi.org/10.1016/j.firesaf.2016.03.002>
- Méndez-Garabetti, Miguel, Bianchini, G., Tardivo, M. L., Caymes Scutari, P. G., & Gil Costa, G. V. (2017). Hybrid-Parallel Uncertainty Reduction Method Applied to Forest Fire Spread Prediction. *Journal of Computer Science and Technology, ISSN-e 1666-6038, Vol. 17, N° 1, 2017, págs. 12-19*, 17(1), 12–19.
- Morgan, P., Hardy, C. C., Swetnam, T. W., Rollins, M. G., Long, D. G., Morgan, P., & The, M. (2001). Mapping fire regimes across time and space: Understanding coarse and fine-scale fire patterns. *International Journal of Wildland Fire*, 10, 329–342. <https://doi.org/10.1071/WF01032>
- Nowak, R. D. (2002). Nonlinear system identification. *Circuits, Systems, and Signal Processing*, 21(1), 109–122. <https://doi.org/10.1007/BF01211655>
- Purica, I., & Bae, D. (2016). Climate Change events induced risk assessment and mapping and a potential insurance policy. *Journal of Earth Science & Climatic Change*, 07(09). <https://doi.org/10.4172/2157-7617.C1.027>
- Qian, X., Li, W., & Yang, M. (2013). Two-stage nested optimization-based uncertainty propagation method for uncertainty reduction. En *Communications in Computer and Information Science* (Vol. 402, pp. 243–252). Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-45037-2_23
- Real, R., & Vargas, J. M. (1996). The Probabilistic Basis of Jaccard's Index of Similarity. *Systematic Biology*, 45(3), 380–385. <https://doi.org/10.1093/sysbio/45.3.380>
- Rothermel, R. C. (1972). *A mathematical model for predicting fire spread in wildland fuels* (Vol. II). Res. Pap. INT-115, US Dept. of Agric., Forest Service, Intermountain Forest and Range Experiment Station. (Ogden, UT.).
- Sano, T., Takeda, T., & Yamasaki, M. (2009). A new uncertainty reduction method for fuel fabrication process with erbia-bearing fuel. *Journal of Nuclear Science and Technology*, 46(3), 226–231. <https://doi.org/10.1080/18811248.2007.9711525>
- Sousa, F. A., dos Reis, R. J. N., & Pereira, J. C. F. (2012). Simulation of surface fire fronts using fireLib and GPUs. *Environmental Modelling & Software*, 38, 167–177. <https://doi.org/10.1016/J.ENVSOFT.2012.06.006>
- Stanford University, & Center for the Study of Language and Information (U.S.). (1997). *Stanford encyclopedia of philosophy*. Stanford University.
- Taghribi, A., & Sharifian, S. (2017). A Metaheuristically Tuned Interval Type 2 Fuzzy System to Reduce Segmentation Uncertainty in Brain MRI Images. *Journal of Medical Systems*, 41(11), 174. <https://doi.org/10.1007/s10916-017-0821-5>
- Tardivo, M. L., Caymes-Scutari, P., Méndez-Garabetti, M., & Bianchini, G. (2018). *Optimization for an uncertainty reduction method applied to forest fires spread prediction*. *Communications in Computer and Information Science* (Vol. 790). https://doi.org/10.1007/978-3-319-75214-3_2
- Thompson, M. P., & Calkin, D. E. (2011). Uncertainty and risk in wildland fire management: A review. *Journal of Environmental Management*, 92(8), 1895–1909. <https://doi.org/10.1016/J.JENVMAN.2011.03.015>
- Tsutsui, S., & Collet, P. (2013). *Massively Parallel Evolutionary Computation on GPGPUs*. Springer Berlin Heidelberg.
- Wallace, G. (1993). A Numerical Fire Simulation-Model. *International Journal of Wildland Fire*, 3(2), 111. <https://doi.org/10.1071/WF9930111>
- Wilkinson, B., & Allen, C. M. (1999). *Parallel Programming: Techniques and Applications Using Networked Workstations and Parallel Computers*. Pearson/Prentice Hall.