

Aplicando un procedimiento de optimización paralelo *Teaching-Learning* para el enfoque automático de heliostatos

N.C. Cruz¹, J.L. Redondo², J.D. Álvarez³, M. Berenguel⁴, P.M. Ortigosa⁵

Resumen—La configuración operativa del campo solar de las centrales solares de recepción central es un aspecto fundamental de sus tareas de control. El subconjunto de heliostatos activos debe configurarse con precisión para alcanzar el estado de funcionamiento deseado y evitando distribuciones de flujo y picos de potencia peligrosos sobre la superficie del receptor. En este contexto, los autores de este trabajo están desarrollando una metodología de enfoque automático general. Sin embargo, la formulación matemática de este problema da lugar a un complejo problema de optimización de amplia escala en el que cada heliostato activo requiere un cierto punto de enfoque bidimensional sobre la superficie del receptor. En este trabajo se estudia la posibilidad de aplicar TLBO, un optimizador basado en poblaciones y diseñado para problemas de optimización de amplia escala. Teniendo en cuenta el potencial coste computacional de este proceso, se ha desarrollado una versión paralela preliminar de TLBO. Se describe la aplicación de este método para realizar una exploración amplia del espacio de búsqueda en un entorno de computación de altas prestaciones. La paralelización del optimizador resulta ser muy útil para acelerar el proceso de búsqueda en el presente problema. Por consiguiente, se facilita la posibilidad de incluir etapas adicionales dentro del método que permitan obtener mejores soluciones.

Palabras clave— Computación paralela, Optimización de amplia escala, TLBO, Enfoque de heliostatos.

I. INTRODUCCIÓN

Las centrales solares de recepción central, CSRC en adelante, son instalaciones de producción de energía eléctrica basadas en el aprovechamiento de la energía solar mediante la concentración de la radiación incidente. En términos generales, y teniendo en cuenta el ámbito de este trabajo, se forman por un amplio conjunto de espejos orientables y altamente reflectantes y un receptor de radiación situado sobre una torre. Los espejos, llamados 'heliostatos', siguen el movimiento aparente del Sol a lo largo del día para concentrar la radiación incidente sobre el receptor. Por consiguiente, se genera una gran densidad de radiación sobre la superficie del receptor. Esta energía se transmite entonces a un fluido caloportador que circula por su interior. Después de aumentar considerablemente su temperatura, este fluido puede final-

mente emplearse en un ciclo termodinámico clásico para la generación de energía eléctrica. En la figura 1 se puede ver un esquema ilustrativo de este tipo de centrales. Algunos de sus aspectos clave son la estabilidad de producción y la eficiencia operativa dada la madurez de las tecnologías subyacentes en las que se basa. Se remite al lector interesado a [2], [10] para obtener más información de las centrales solares de recepción central.




Fig. 1. Esquema de una central solar de recepción central.

El control de la distribución de flujo que forma el campo de heliostatos sobre la superficie del receptor es de vital importancia para evitar gradientes de temperatura peligrosos, estrés térmico y el envejecimiento prematuro de sus componentes [1], [3], [5], [8], [12]. Es un factor clave para aumentar el tiempo de vida útil del receptor, lo que tiene una repercusión directa en los costes de las CSRC como se destaca en [8]. Teniendo en cuenta que el campo de heliostatos está formado normalmente por cientos (incluso miles) de heliostatos, la definición del subconjunto de ellos a activar en un momento dado, así como sus correspondientes puntos de enfoque según la distribución de flujo a lograr, lleva a resolver un complejo problema de varios niveles de decisión. En [3], [8] este problema se aborda fijando un conjunto de heliostatos y otro de puntos de enfoque disponibles, para obtener una distribución homogénea, con buenos resultados. Sin embargo, en el contexto de este trabajo, se está desarrollando una generalización del concepto tratando de configurar automáticamente todo el campo, para un cierto instante de tiempo (una determinada posición solar), y una distribución de flujo cualquiera a obtener. El procedimiento diseñado habría de ser capaz incluso de desactivar aquellos heliostatos innecesarios para replicar una distribución de referencia deseada (dado que los campos solares suelen estar sobredimensionados para afrontar situaciones desfavorables como días nublados). En cualquier caso, esta etapa de selección quedaría fuera del alcance del

¹Dpto. de Informática, Univ. de Almería, CeiA3, e-mail: ncalvocruz@ual.es.

²Dpto. de Informática, Univ. de Almería, CeiA3, e-mail: j.lredondo@ual.es.

³Dpto. de Informática, Univ. de Almería, CeiA3, e-mail: jbervas@ual.es.

⁴Dpto. de Informática, Univ. de Almería, CeiA3, e-mail: beren@ual.es.

⁵Dpto. de Informática, Univ. de Almería, CeiA3, e-mail: ortigosa@ual.es.

presente documento y se asume de entrada que el conjunto de helióstatos activos ya se conoce. En este punto, se obtienen en general buenos resultados aplicando optimizadores basados en la dirección del gradiente. Desafortunadamente, estas estrategias tienen un ámbito local y se sabe que la función objetivo tiene múltiples óptimos locales. Se pretende por tanto incluir en el procedimiento un optimizador global eficiente que permita obtener una perspectiva amplia del problema. Se ha decidido considerar un optimizador global basado en poblaciones existente y especialmente orientado a problemas de amplia escala, el algoritmo ‘Teaching-Learning-Based Optimization’ (TLBO) [6]. Por consiguiente, el despliegue y evaluación de este método en un entorno de computación de altas prestaciones es el principal objetivo de este trabajo.

En la sección II se describe formalmente el problema abordado. Seguidamente, en la sección III, se explica el algoritmo TLBO. En la sección IV se comenta la estrategia de paralelización del algoritmo seguida. Finalmente, la experimentación realizada y las conclusiones obtenidas se detallan en las secciones V y VI respectivamente.

II. DEFINICIÓN DEL PROBLEMA

Con objeto de modelar el presente problema es necesario, en primer lugar, definir la distribución de flujo que se pretende conseguir, F . Se trata de una matriz $Y \times X$ donde Y y X son el número de filas y columnas respectivamente. Todos los elementos de F son conocidos, tanto en magnitud (densidad de flujo) como posición, dado que forma parte de la información de entrada del problema. Esta matriz puede verse como una ‘imagen’ de la distribución de flujo a replicar sobre el receptor, que se modela como un rectángulo plano, con los helióstatos activos. Su dimensión Y_P está ligada a la vertical del plano, con dirección hacia el cénit desde la base de la torre en un sistema de coordenadas cartesianas tridimensional. En relación a su dimensión lateral X_P , se extiende en la dirección horizontal del plano desde el Oeste hacia el Este. En este contexto, los ejes de discretización son también conocidos como los vectores $Y' = y_0, \dots, y_Y$ y $X' = x_0, \dots, x_X$ cuya longitud es Y y X respectivamente. Por consiguiente, cada elemento de la matriz hace referencia a una zona particular del receptor, cuya superficie está implícitamente discretizada por el paso usado al definir F .

En relación a los helióstatos activos, se trata de un conjunto ordenado $H = \{h_1, h_s, \dots, h_T\}$ con cardinalidad T . Cada helióstato h_i proyecta una cierta distribución de flujo sobre el receptor cuando está operativo, que es una función bidimensional conocida de la densidad de radiación. Se define como una función de densidad gaussiana bidimensional como se muestra en la ecuación 1. En dicha ecuación, x e y son las coordenadas sobre el plano rectangular del receptor en sus dimensiones X_P e Y_P respectivamente, P es la contribución de potencia del helióstato h_i

sobre el receptor, ρ es la correlación entre x e y , y σ_x y σ_y son la desviación típica a lo largo de x e y respectivamente. En relación a μ_x y μ_y , las medias en la función de probabilidad gaussiana, definen el punto central de la distribución de flujo, es decir, el punto de enfoque del helióstato h_i . Este esquema de modelado es similar al seguido en [3], [8], donde se aplica una función de densidad gaussiana circular siguiendo el modelo de HFLCAL [9]. Todos los parámetros que definen la forma de la distribución de flujo de cada helióstato, es decir, P , ρ , σ_x y σ_y son conocidas (en nuestro caso a partir de simulaciones detalladas y procesos de ajuste de curvas). Sin embargo, su punto central de enfoque, (μ_x, μ_y) , debe determinarse para replicar la distribución de flujo de referencia. Una vez que todos los helióstatos tienen un cierto punto de enfoque asignado, el vector de configuración del campo, c , puede entonces definirse concatenando el par de coordenadas de enfoque de cada uno. Finalmente, la distribución de flujo obtenida según dicha configuración, F^*c , se forma a partir de la convolución de la correspondiente a cada helióstato sobre el receptor, a lo largo de los ejes de discretización y dando lugar a una matriz de las mismas dimensiones que F .

Teniendo en cuenta las definiciones previas, se puede plantear un problema de minimización $2T$ -dimensional sobre la acumulación de la diferencia al cuadrado, en cada punto de discretización, entre las matrices F y F^*c como se muestra en la ecuación 2

$$\min O = \min \sum_{x=x_0}^{x_X} \sum_{y=y_0}^{y_Y} (F(x, y) - F^*c(x, y))^2 \quad (2)$$

III. OPTIMIZACIÓN ‘Teaching-Learning’ (TLBO)

‘Teaching-Learning-Based Optimization’ (TLBO) es un algoritmo de optimización global estocástico, basado en poblaciones y orientado a problemas de amplia escala presentado en [6]. Se basa en modelar el comportamiento de una clase de estudiantes formada por un conjunto de soluciones candidatas conocidas. Estas soluciones se van mejorando progresivamente mediante la simulación tanto del proceso de enseñanza de un profesor como de la interacción entre los alumnos. Este algoritmo se caracteriza fundamentalmente por su rendimiento y por su falta de parámetros específicos de búsqueda, ya que sólo es necesario especificar el tamaño de la población y el número de ciclos según se requiera. A pesar de que en este trabajo se ha seleccionado para una primera exploración la versión básica del algoritmo para problemas de optimización continua sin restricciones, se recomienda al lector interesado la lectura de [7] para mayor información sobre TLBO, sus versiones y aplicaciones. Adicionalmente, la lectura de los trabajos de [4] y [11] es también muy recomendable.

Los ‘estudiantes’, es decir, las soluciones candidatas, se definen como vectores N -dimensionales, donde N es el número de dimensiones del problema

$$f_{h_i}(x, y) = \frac{P}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} e^{\left(-\frac{1}{2(1-\rho^2)}\left(\frac{(x-\mu_x)^2}{\sigma_x^2} + \frac{(y-\mu_y)^2}{\sigma_y^2} - 2\rho\frac{(x-\mu_x)(y-\mu_y)}{\sigma_x\sigma_y}\right)\right)} \quad (1)$$

abordado. Cada dimensión se considera como una ‘asignatura’ en el contexto de TLBO, y la representación natural de la población o ‘clase’ es una matriz $P \times N$, siendo P el número de individuos disponibles. Se asume que la calidad o rendimiento de los estudiantes sigue una distribución normal cuyo valor medio debe mejorarse mediante la interacción académica. Por consiguiente, el valor de los estudiantes en cada asignatura se va alterando a lo largo de los ciclos con el objetivo de mejorar la media general. Para lograrlo, TLBO se apoya en dos pasos fundamentales por ciclo, las fases del profesor (*Teacher Phase (TS)*) y la de los alumnos o aprendices (*Learners Phase (LS)*). Ambas se resumen a continuación, para un cierto ciclo k , desde una perspectiva de problema minimización.

A. Fase del profesor (TS)

En esta etapa se comienza calculando el valor medio actual por asignatura o dimensión, es decir, por columnas en la matriz de población previamente comentada. De esta forma, se obtiene un vector N -dimensional M . Entonces, el mejor estudiante de la población, cuyo valor de la función objetivo es el menor de los conocidos, se selecciona como profesor del ciclo. Seguidamente, se calcula un entero aleatorio en el rango [1, 2] denominado factor de enseñanza (*Teaching Factor (T_F)*). Este valor supone un factor de ponderación general de las capacidades de enseñanza del profesor. Posteriormente, se genera un vector N -dimensional aleatorio de valores reales, r , en el rango [0, 1], para modelar la capacidad de docencia del profesor, en cada asignatura, en relación con los estudiantes. Con esta información se calcula entonces un vector de desplazamiento general DM , de dimensión N , según la ecuación 3 (donde los operadores tienen una componente dimensional o ‘elemento a elemento’). Finalmente, este vector se suma a cada individuo existente. Sin embargo, sólo aquellos que se ven mejorados por el cambio, tras evaluarlos, se mantienen. En caso contrario este cambio se deshace.

$$DM = r(T - T_F M) \quad (3)$$

B. Fase de los alumnos (LS)

En esta etapa se comienza por generar un vector N -dimensional de valores reales, r , en los mismos términos que el vector homónimo de la etapa anterior. En esta ocasión modela la capacidad puntual de avance de los alumnos, en cada asignatura, a través de su interacción. Seguidamente, cada individuo final i de la etapa anterior se empareja con otro, diferente de sí mismo, j . A continuación, se intenta desplazar al individuo i de su posición actual en una dirección que depende de su valor relativo con respecto a j , tal y como se comenta en la ecuación 4

(manteniendo el carácter ‘elemento a elemento’ de la operación). Finalmente, el individuo i sólo será actualizado si su valor se ve mejorado tras el cambio.

Llegados a este punto, la población del siguiente ciclo quedaría en principio definida. Sin embargo, aunque no se menciona en [6], es posible la inclusión de un paso adicional para la eliminación de soluciones duplicadas. Este detalle se destaca en [4] y se responde en [11]. Este proceso ha de buscar soluciones candidatas iguales y reinicializar aleatoriamente alguna dimensión de una de ellas dando lugar a una nueva solución candidata. Dicha fase también se ha incluido en la implementación realizada para este trabajo.

IV. ESTRATEGIA DE PARALELIZACIÓN

Teniendo en cuenta la descripción realizada de la estructura y funcionamiento de TLBO, y asumiendo además una función objetivo computacionalmente costosa de evaluar, los procesos iterativos subyacentes en las etapas TS y LS (el intento de actuación y evaluación de cada individuo) podrían asignarse a distintas unidades de ejecución. De esta forma, el procedimiento se mantendría perfectamente consistente con el secuencial pero, en cada ciclo, las tareas de gestión de los individuos se repartirían entre las unidades de ejecución disponibles. Por consiguiente, las evaluaciones requeridas de la función objetivo se repartirían entre las mismas. Esta es la estrategia que se ha seguido en el presente trabajo en un entorno de concurrencia real basada en hilos. Su eficiencia depende directamente del tamaño de la población y el coste de su evaluación. Queda, sin embargo, teóricamente desligada del número de ciclos de búsqueda.

Finalmente, es importante mencionar que para poblaciones extremadamente grandes (a fin de ampliar la búsqueda) y/o funciones objetivo muy costosas, la estrategia descrita podría ser fácilmente generalizada. En concreto, la población podría ser dividida en subconjuntos disjuntos y ser internamente gestionada en paralelo con puntos de intercambio y sincronización intermedios. De esta forma sería interesante para un entorno híbrido combinando procesos independientes e hilos cuando el problema abordado permitiera amortizar el coste de las comunicaciones.

V. EXPERIMENTACIÓN Y RESULTADOS

Una instancia de muestra del presente problema pretendería formar una distribución de flujo uniforme y plana sobre el receptor. Por consiguiente, la matriz F estaría formada por un único elemento replicado. En este caso de estudio se está ante una forma plana a $80kW/m^2$ sobre un receptor de 6×6 metros. El subconjunto de helióstatos a activar ya habría sido seleccionado por las capas superiores de

$$Estudiante_i = \begin{cases} Estudiante_i + r(Estudiante_j - Estudiante_i), & \text{Si } j \text{ mejor que } i \\ Estudiante_i + r(Estudiante_i - Estudiante_j), & \text{Si } i \text{ mejor que } j \end{cases} \quad (4)$$

nuestro procedimiento dando lugar a un conjunto de 110 elementos. En este contexto, se va a lanzar la implementación paralela de TLBO para evaluar su rendimiento computacional. Ésta ha sido desarrollada en el lenguaje de programación C con directivas OpenMP para temas de hebrado.

La plataforma de ejecución es un nodo de cluster con procesador Intel Xeon E5 2650v2 con 16 núcleos y 128 GB de memoria RAM. El número de ciclos se ha fijado a 150 tras una etapa de ajuste preliminar. En relación al número de individuos de la población, lo que marca el coste computacional directo de cada ciclo, se ha configurado para ser 50, 100, 200 y 400. Teniendo en cuenta el equipo disponible, el número de hilos desplegado en las pruebas ha sido de 2, 4, 8 y 16 para todos los tamaños de población.

En la figura 2 se muestra la aceleración obtenida con la versión paralela de TLBO para los distintos tamaños de población. Adicionalmente, se incluye como referencia una línea punteada negra que representa la aceleración teórica lineal. Los resultados mostrados se han promediado tras cinco ejecuciones. Como se puede apreciar, la aceleración conseguida es casi lineal en todos los casos. De hecho, con 2 y 4 hilos podría considerarse lineal independientemente del tamaño de la población. El pico de rendimiento se logra con la mayor población evaluada, 400 individuos, y 16 hilos, llegando a una aceleración de 14.10. Sin embargo, como es de esperar, se reduce conforme el tamaño de la población se reduce y el número de hilos es demasiado elevado. Dicho en otras palabras, la aceleración se va alejando progresivamente de la linealidad cuando el ratio entre individuos e hilos activos se reduce. Nótese, no obstante, la escalabilidad del procedimiento dada la tendencia monótonamente creciente de la aceleración en todas las configuraciones probadas.




Fig. 2. Aceleración obtenida con la versión hebrada de TLBO.

Finalmente, en la figura 3 se muestra la distribución de flujo correspondiente a la mejor solución encontrada por TLBO. Se ha obtenido con una población de 400 individuos a lo largo de 150 ciclos de búsqueda. Como se puede apreciar, su zona superior es relativamente plana y próxima a $80kW/m^2$ como se pretendía. Por consiguiente, el algoritmo no sólo se muestra apto para ser paralelizado eficientemente con este problema, sino que sus resultados parecen prometedores como puntos de partida de optimizadores locales basados en gradiente.




Fig. 3. Plano X-Z de la solución obtenida por TLBO al replicar una forma plana.

VI. CONCLUSIONES Y TRABAJO FUTURO

En este trabajo se ha presentado el problema que supone la definición del punto de enfoque de un conjunto de helióstatos en una central solar de recepción central. A continuación, se ha formalizado matemáticamente como un problema de optimización (minimización) de amplia escala sin restricciones. Se sabe de dicho problema que tiene numerosos óptimos locales y una complejidad que crece con el número de helióstatos. En este contexto, se ha decidido estudiar el comportamiento de un algoritmo de optimización global eficiente, basado en poblaciones y especialmente destinado a problemas de amplia escala, TLBO. Se pretende fundamentalmente que permita exploraciones amplias del espacio de búsqueda con grandes poblaciones. Por este motivo, y considerando además el coste computacional de la función objetivo, se ha implementado una versión de TLBO paralela, basada en hilos, bajo el soporte de Open-MP. Ha mostrado una aceleración casi lineal y un comportamiento muy escalable con resultados aceptables en el dominio del problema. Por consiguiente, TLBO parece adecuado para usarse como guía de ámbito global de un proceso con etapas de refinamiento o búsqueda local.

Como trabajo futuro, teniendo en cuenta los resultados positivos obtenidos, se va a considerar en

profundidad la inclusión de TLBO paralelo en el procedimiento de enfoque automático de heliostatos desarrollado por los autores de este trabajo. Adicionalmente, se abordará la posibilidad de desplegar una versión paralela híbrida de TLBO que pudiera ejecutarse en diferentes nodos de un cluster.

AGRADECIMIENTOS

Este trabajo ha sido financiado con fondos del Ministerio Español de Economía y Competitividad (TIN2015-66680-C2-1-R y ENERPRO DPI 2014-56364-C2-1-R), Junta de Andalucía (P11-TIC7176 and P12-TIC301). Nicolás Calvo Cruz es beneficiario de una beca FPU del Ministerio Español de Educación. Juana López Redondo y José Domingo Álvarez Hervás están dentro del programa de contratación 'Ramón y Cajal', co-financiado por el Fondo Social Europeo.

REFERENCIAS

- [1] M. Carasso y M. Becker. *Solar Thermal Central Receiver Systems: Performance evaluation standards for solar central receivers (Vol. 3)*. Springer Verlag, 1991.
- [2] O. Behar, A. Khellaf y K. Mohammedi. A review of studies on central receiver solar thermal power plants. *Renewable and Sustainable Energy Reviews*, 23:12-39, 2013.
- [3] S.M. Besarati, D.Y. Goswami y E.K. Stefanakos. Optimal heliostat aiming strategy for uniform distribution of heat flux on the receiver of a solar power tower plant. *Energy Conversion and Management*, 84:234-243, 2014.
- [4] M. Crepinsek, S.H. Liu y L. Mernik. A note on teaching-learning-based optimization algorithm. *Information Sciences*, 212:79-93, 2012.
- [5] A. Grobler y P. Gauché. A review of aiming strategies for central receivers. En 2nd SASEC Conference, 2014.
- [6] R.V. Rao, V.J. Savsani y D.P. Vakharia. Teaching-learning-based optimization: an optimization method for continuous non-linear large scale problems. *Information Sciences*, 183(1):1-15, 2012.
- [7] R.V. Rao. *Teaching Learning Based Optimization Algorithm: And Its Engineering Applications*. Springer, 2015.
- [8] A. Salomé, F. Chhel, G. Flamant, A. Ferrère y F. Thierry. Control of the flux distribution on a solar tower receiver using an optimized aiming point strategy: Application to THEMIS. *Solar Energy*, 94:352-366, 2013.
- [9] P. Schwarzbözl, M. Schmitz y R. Pitz-Paal. Visual HFLCAL - A Software Tool for Layout and Optimisation of Heliostat Fields. En SolarPACES'09, 2009.
- [10] W. Stine y M. Geyer. *Power from the Sun*, 2001. Public website, available from <http://powerfromthesun.net/book.html> (Last access: May 10, 2016)
- [11] G. Waghmare. Comments on 'A note on teaching-learning-based optimization algorithm'. *Information Sciences*, 229:159-169, 2013.
- [12] C.J. Winter, R.L. Sizmann y L.L. Vant-Hull. *Solar power plants: fundamentals, technology, systems, economics*. Springer-Verlag New York, 1991.