



---

---

**UNIVERSIDAD AUTÓNOMA DE YUCATÁN**  
FACULTAD DE INGENIERÍA

**ANÁLISIS TECNO-ECONÓMICO PARA LA  
IMPLEMENTACIÓN DE COLECTORES SOLARES  
DE PLACA PLANA EN LA INDUSTRIA LÁCTEA EN  
MÉXICO: UN ENFOQUE DESDE REDES  
NEURONALES ARTIFICIALES Y OPTIMIZACIÓN  
MULTIOBJETIVO**

**TESIS**

PRESENTADA POR:

**I.F. VÍCTOR CARDOSO FERNÁNDEZ**

EN OPCIÓN AL GRADO DE:

**MAESTRO EN INGENIERÍA**

OPCIÓN ENERGÍAS RENOVABLES

MÉRIDA, YUCATÁN, MÉXICO

2021

Aunque este trabajo hubiere servido para el Examen Profesional y hubiere sido aprobado por el sínodo, solo el autor es responsable de las doctrinas emitidas en él.

## Resumen

En el presente trabajo se desarrolla una metodología computacional para el estudio de un campo de colectores solares de placa plana capaces de suministrar calor solar al proceso industrial de pasteurización láctea. Se propone un tanque intercambiador de calor para aprovechar la energía térmica proveniente de los colectores solares; además, se considera un calentador auxiliar en caso que el calor solar no satisfaga por completo la demanda industrial. El análisis se realiza para los tipos de clima templado, árido, seco y tropical, contemplando también cuatro escenarios de combustible para el calentador auxiliar: diésel, combustóleo, gas natural y gas LP. Las variables de diseño consideradas para la experimentación numérica son el área ocupada por el campo solar, el volumen del tanque intercambiador de calor, el combustible para el calentador auxiliar y el tipo de clima. Considerando las ecuaciones gobernantes de la tecnología solar, las características térmicas del proceso industrial y las condiciones climáticas de la región bajo análisis, se crea una base de datos a partir de los resultados numéricos obtenidos al modificar numéricamente los parámetros de diseño. Esta base de datos es utilizada para entrenar un modelo sustituto de inteligencia artificial basado en redes neuronales artificiales; las neuronas en la capa de entrada son los cuatro parámetros de diseño, mientras que las neuronas en la capa de salida son los indicadores económico-ambientales: valor presente neto, costo total del ciclo de vida y la reducción en la emisión de dióxido de carbono. Finalmente, se lleva a cabo un proceso de optimización multiobjetivo sobre el modelo de inteligencia artificial a través del algoritmo de enjambre de partículas, algoritmo genético y algoritmo de optimización de ballenas, para la obtención de los diagramas de Pareto asociados a las variables de salida del modelo sustituto. Los resultados muestran que las cuatro regiones climáticas presentan factibilidad económico-ambiental cuando se emplea diésel como combustible para el calentador auxiliar, siendo el clima templado de Jalisco el más adecuado para la implementación de esta tecnología solar. La metodología computacional desarrollada puede ser empleada para analizar la factibilidad económico-ambiental que resulta de implementar distintos tipos de tecnología solar al proceso industrial de interés.

## Abstract

In the present work, a computational methodology is developed for the study of a field of flat plate solar collectors capable of supplying solar heat to the industrial process of dairy pasteurization. A heat exchanger tank is proposed to obtain the thermal energy coming from the solar collectors; in addition, an auxiliary heater is considered in case the solar heat does not fully satisfy the industrial demand. The analysis is carried out for temperate, arid, dry and tropical climate types, also considering four fuel scenarios for the auxiliary heater: diesel, fuel oil, natural gas and LP gas. The design variables considered for the numerical experimentation are the area occupied by the solar field, the volume of the heat exchanger tank, the fuel for the auxiliary heater and the type of climate. Considering the governing equations of the solar technology, the thermal characteristics of the industrial process and the climatic conditions of the region under analysis, a database is created from the numerical results obtained by numerically modifying the design parameters. This database is used to train a surrogate model of artificial intelligence based on artificial neural networks; neurons in the input layer are the four design parameters, while neurons in the output layer are the economic-environmental indicators: net present value, total life cycle cost and reduction in carbon dioxide emissions. Finally, a multiobjective optimization process is carried out on the artificial intelligence model through the particle swarm algorithm, genetic algorithm and whale optimization algorithm, to obtain the Pareto diagrams associated with the output variables of the surrogate model. The results show that the four climatic regions present economic-environmental feasibility when diesel is used as fuel for the auxiliary heater, being the temperate climate of Jalisco the most suitable for the implementation of this solar technology. The computational methodology developed can be used to analyze the economic-environmental feasibility that results from implementing different types of solar technology to the industrial process of interest.

## Agradecimientos

El autor de este documento agradece en exceso al Consejo Nacional de Ciencia y Tecnología (CONACYT) por el apoyo financiero otorgado para la realización del presente trabajo de maestría, otorgado a partir de la beca escolar de posgrado CONACYT número 752330 (CVU 1006703).

## Contenido

Resumen .....	2
Abstract .....	3
Agradecimientos.....	4
Índice de Figuras.....	7
Índice de Tablas .....	9
Introducción.....	10
Antecedentes.....	12
Justificación .....	16
Hipótesis.....	18
Objetivo General.....	18
Objetivos específicos .....	18
Capítulo 1. Calor solar para el proceso industrial.....	19
1.1 Tecnología solar térmica aplicada a la industria .....	21
1.2 Colectores solares de placa plana para calor solar en México .....	24
1.3 Características del colector solar de placa plana.....	28
1.3.1 Balance de energía y ecuaciones gobernantes .....	29
1.3.2 Tecnología comercial .....	34
1.4 Descripción y análisis del sistema SHIP .....	35
1.5 Indicadores de viabilidad económica y ambiental para el sistema SHIP .....	37
1.5.1 Indicador de viabilidad económica: NPV .....	38
1.5.2 Indicador de viabilidad económica: TLCC .....	39
1.5.3 Indicador de viabilidad ambiental: ACM .....	40
Capítulo 2. Herramientas computacionales avanzadas .....	41

2.1 Redes neuronales artificiales.....	41
2.2 Optimización multiobjetivo .....	45
2.2.1 Algoritmo genético.....	46
2.2.2 Algoritmo de enjambre de partículas.....	49
2.2.3 Algoritmo de optimización de ballena.....	52
Capítulo 3. Metodología computacional .....	55
3.1 Descripción del caso de estudio .....	55
3.2 Entrenamiento de la red neuronal artificial.....	60
3.3 Implementación de algoritmos de optimización .....	62
Capítulo 4. Análisis de resultados .....	64
4.1 Red neuronal artificial como modelo sustituto del sistema SHIP .....	64
4.2 Optimización multiobjetivo mediante GA, PSO y WOA .....	66
Conclusiones.....	75
Referencias .....	78
Anexo 1 .....	85
Anexo 2 .....	93

## Índice de Figuras

<b>Figura 1.1</b> Procesos industriales, demanda de calor y tecnología solar capaz de satisfacer dicha demanda (Solar Payback, 2018) .....	23
<b>Figura 1.2</b> Tecnología solar instalada a nivel nacional para brindar calor a procesos industriales (AEE INTEC, 2020).....	25
<b>Figura 1.3</b> Principales componentes del colector solar plano considerados para el análisis energético.....	29
<b>Figura 1.4</b> Colector solar MS 1.9 UE de dimensiones 2045 x 931 mm y 31.6 kg, con su respectiva curva de eficiencia (Módulo Solar, 2019).....	34
<b>Figura 1.5</b> Sistema industrial con calor solar integrado. (a) cuenta con la configuración del calentador auxiliar en paralelo y (b) en serie (Kalogirou S. A., 2009).....	35
<b>Figura 1.6</b> Análisis térmico del volumen de control asociado al sistema SHIP. ....	36
<b>Figura 2.1</b> Representación de las partes de una neurona y su analogía con una neurona artificial. ....	42
<b>Figura 2.2</b> Representación esquemática de una red neuronal artificial (Kalogirou S. , 2001) .....	43
<b>Figura 2.3</b> Partes que componen una neurona artificial. ....	44
<b>Figura 2.4</b> Principales etapas del algoritmo genético. ....	47
<b>Figura 2.5</b> Pseudocódigo para el algoritmo genético (Euskal Herriko Unibersitatea, 2019) .....	48
<b>Figura 2.6</b> Representación del comportamiento característico de los individuos sometidos al algoritmo de enjambre de partículas. ....	49
<b>Figura 2.7</b> Pseudocódigo para el algoritmo de optimización de enjambre de partículas (Slowik, 2018).....	50
<b>Figura 2.8</b> Descripción esquemática de las dos etapas en las que se divide el algoritmo de optimización de ballenas: a) Búsqueda superficial y b) Movimiento espiral de contracción (Mirjalili & Lewis, 2016) .....	52
<b>Figura 2.9</b> Pseudocódigo para el algoritmo de optimización de ballenas (Mirjalili & Lewis, 2016).....	54



<b>Figura 3.1</b> Demanda energética anual del proceso de pasteurización láctea.....	56
<b>Figura 3.2</b> Diagrama esquemático del sistema SHIP empleando colectores solares de placa plana .....	57
<b>Figura 3.3</b> Mapa climático con la ubicación de los cuatro climas representativos seleccionados a nivel nacional. ....	59
<b>Figura 3.4</b> Estructura metodológica desarrollada en el presente trabajo.....	63
<b>Figura 4.1</b> Arquitectura de la ANN que incluye todos los procedimientos realizados en el sistema SHIP.....	64
<b>Figura 4.2</b> Gráficas de regresión para las distintas etapas de entrenamiento de la ANN..	66
<b>Figura 4.3</b> Diagramas de Pareto obtenidos mediante los distintos algoritmos de optimización, considerando los 4 combustibles del calentador auxiliar para el clima de Coahuila .....	71
<b>Figura 4.4</b> Diagramas de Pareto obtenidos mediante los distintos algoritmos de optimización, considerando los 4 combustibles del calentador auxiliar para el clima de Jalisco .....	72
<b>Figura 4.5</b> Diagramas de Pareto obtenidos mediante los distintos algoritmos de optimización, considerando los 4 combustibles del calentador auxiliar para el clima de Mérida .....	73
<b>Figura 4.6</b> Diagramas de Pareto obtenidos mediante los distintos algoritmos de optimización, considerando los 4 combustibles del calentador auxiliar para el clima de Monterrey .....	74

## Índice de Tablas

<b>Tabla 1.1</b> Procesos industriales y sus demandas de temperatura (IRENA, 2015).....	19
<b>Tabla 1.2</b> Clasificación de los colectores solares (Kalogirou S. A., 2009) .....	21
<b>Tabla 1.3</b> Costos reportados para distintos colectores solares empleados en la industria (Sharma A. K., Sharma, Mullick, & Kandpal, 2017).....	24
<b>Tabla 1.4</b> Capacidad instalada de los colectores solares de placa plana en México a partir del subsector industrial (AEE INTEC, 2020).....	26
<b>Tabla 1.5</b> Parámetros económicos considerados para el sistema de calor solar implementado en el mercado mexicano .....	39
<b>Tabla 1.6</b> Características ambientales de los combustibles considerados para el sistema de calefacción de respaldo (INECC, 2014) .....	40
<b>Tabla 3.1</b> Características técnicas y operativas del sistema SHIP (May Tzuc, 2020).....	57
<b>Tabla 3.2</b> Parámetros considerados para determinar la viabilidad económica y ambiental del sistema SHIP (May Tzuc, 2020).....	60
<b>Tabla 4.1</b> Resultados estadísticos obtenidos al variar el número de neuronas en la capa oculta.....	65
<b>Tabla 4.2</b> Parámetros de diseño del sistema SHIP obtenidos mediante los distintos algoritmos de optimización para el caso de Coahuila, considerando los 4 escenarios de combustible para el calentador auxiliar. ....	68
<b>Tabla 4.3</b> Parámetros de diseño del sistema SHIP obtenidos mediante los distintos algoritmos de optimización para el caso de Jalisco, considerando los 4 escenarios de combustible para el calentador auxiliar. ....	68
<b>Tabla 4.4</b> Parámetros de diseño del sistema SHIP obtenidos mediante los distintos algoritmos de optimización para el caso de Mérida, considerando los 4 escenarios de combustible para el calentador auxiliar. ....	69
<b>Tabla 4.5</b> Parámetros de diseño del sistema SHIP obtenidos mediante los distintos algoritmos de optimización para el caso de Monterrey, considerando los 4 escenarios de combustible para el calentador auxiliar. ....	69

## Introducción

La necesidad de calor por parte de la industria para llevar a cabo distintos procesos ha existido desde los inicios de la revolución industrial. La quema de combustibles fósiles para satisfacer las necesidades energéticas representa una práctica no sostenible. Además, la demanda energética en el sector industrial no presenta tendencia alguna a disminuir. Esta demanda es originada por los productos que los seres humanos consumimos; en caso del presente trabajo, la demanda de productos lácteos. Como todo proceso energético que emplea combustibles fósiles, la emisión de gases contaminantes a la atmósfera se presenta como una consecuencia no deseada del proceso industrial. Debido a factores como el subsidio proporcionado a los combustibles fósiles, así como el elevado precio de las tecnologías termosolares, no es económicamente rentable sustituir por completo las tecnologías de generación térmica empleadas actualmente en la industria por aquellas que funcionan a partir de la energía solar. Dentro de los principales retos que se necesitan superar para implementar la tecnología termosolar a nivel industrial, se encuentra la estandarización en los procesos de diseño, instalación y puesta en marcha, ya que actualmente no se cuenta con un marco normativo específico. Además, los proyectos que emplean calor solar para procesos industriales (SHIP, por sus siglas en inglés) requieren inversiones iniciales considerables en comparación con las unidades de generación de calor con combustible fósil (SolarPayback, 2018). Una posible solución ante esta problemática es la implementación de tecnología solar térmica para suministrar parte del calor demandado, junto con un calentador auxiliar que brinde el calor faltante a través de combustibles fósiles; sin embargo, ésta aún no ha sido muy estudiada, de tal manera que se desconoce la rentabilidad de dicha opción.

El presente trabajo de tesis se encuentra integrado por un total de cuatro capítulos los cuales son descritos de forma breve a continuación:

## **Capítulo 1.- CALOR SOLAR PARA EL PROCESO INDUSTRIAL**

Presenta el estado actual de las tecnologías empleadas para brindar calor solar a distintos procesos industriales. Se describe la demanda energética de los principales procesos de calor solar en México, así como las características de operación de las tecnologías solares capaces de satisfacer dicha demanda. Menciona los distintos indicadores empleados para describir las características económicas y ambientales del proceso industrial.

## **Capítulo 2.- HERRAMIENTAS COMPUTACIONALES AVANZADAS**

Describe las características y principio de funcionamiento de las redes neuronales artificiales, empleadas para modelar la relación entre los parámetros de diseño y las variables dependientes del sistema SHIP, a través de la creación de un modelo sustituto. El algoritmo genético (GA), enjambre de partículas (PSO) y optimización de ballena (WOA) son utilizados para realizar una evaluación comparativa de desempeño multiobjetivo.

## **Capítulo 3.- METODOLOGÍA COMPUTACIONAL**

Explica la estrategia computacional propuesta para modelar el comportamiento térmico y energético de una planta industrial del sector lácteo, así como el desarrollo del modelo de inteligencia artificial basado en redes neuronales artificiales, construido a partir de los resultados numéricos obtenidos de la planta. Presenta la integración del modelo de inteligencia artificial a los tres algoritmos de evaluación multiobjetivo mencionados en el capítulo anterior, buscando optimizar las variables dependientes del sistema SHIP.

## **Capítulo 4.- ANÁLISIS DE RESULTADOS**

Muestra los resultados obtenidos tras la implementación de la metodología descrita en el capítulo 3. Valida el modelo de inteligencia artificial mediante la comparación de los resultados obtenidos para la planta industrial láctea. Finalmente, presenta un análisis de optimización multiobjetivo mediante distintos algoritmos para determinar la viabilidad económica y ambiental.

## Antecedentes

La tecnología solar es una herramienta que ha permitido obtener energía limpia, evitando la quema de combustibles fósiles y disminuyendo la emisión de gases contaminantes a la atmósfera. A nivel industrial, debido a la proporción de energía térmica demandada en comparación con un sistema termosolar para un domicilio o comercio, el impacto que tiene esta tecnología es aún mayor. Diversos estudios han sido realizados a nivel industrial para analizar la factibilidad de estos sistemas. En Casablanca, Marruecos, se implementó un sistema de calentamiento solar centralizado para suministrar el calor necesario a 4 procesos característicos de la pasteurización en una industria láctea (Allouhi, Agrouaz, Amine, et al., 2017). En Argentina, se estudiaron distintas tecnologías de colectores solares, parabólico compuesto, lineal de Fresnel y de cilindro parabólico, para satisfacer demandas de calor industrial; a manera de resultado, se presentaron el costo nivelado de calor, así como la emisión de gases contaminantes para cada tecnología (Lillo, Pérez, Moreno, et al., 2017). También es posible emplear colectores solares de placa plana con energía geotérmica para obtener salidas de energía a alta y baja temperatura, con el fin de cubrir distintas aplicaciones (Bellos & Tzivanidis, 2020).

Los análisis económicos realizados sobre los sistemas de aprovechamiento de la energía solar permiten estimar el costo mínimo necesario para satisfacer una demanda, considerando tanto el sistema de aprovechamiento solar, así como fuentes alternativas no renovables (Kalogirou S. A., 2004). En cuanto a los estudios ambientales, éstos marcan un claro potencial en la mitigación del uso de carbono y la emisión de gases de efecto invernadero, al emplear calor solar en la industria de papel y textil en países como India (Sharma, Sharma, Mullick, et al., 2015; Sharma, Sharma, Mullick, et al., 2016). El impacto económico causado por el empleo de SHIP en estas industrias en India fue analizado a través de indicadores como el costo nivelado unitario de energía térmica utilizable, el periodo de recuperación descontado, el valor presente neto y la tasa de retorno interna de la inversión (Sharma, Sharma, Mullick, et al., 2018).

Los estudios experimentales son poco comunes en sistemas de calor solar para procesos industriales, ya que éstos suelen estar fuera del presupuesto de las empresas y en muchas ocasiones es necesario detener procesos debido a la implementación de sistemas de monitoreo y obtención de datos necesarios para el estudio. Las distintas herramientas desarrolladas a partir de la inteligencia artificial permiten estimar la cantidad de energía que entrega un sistema de captación de energía solar, a partir de datos numéricos obtenidos previamente de dicho sistema (Kalogirou S. A., 2004). Se han desarrollado herramientas computacionales que describen los parámetros térmicos y energéticos de un campo de colectores solares que suministran SHIP, las cuales obtienen resultados muy cercanos a los presentados a través de software comercial. Una de estas herramientas permite calcular la temperatura del fluido dentro del tanque de almacenamiento, el calor que es posible utilizar obtenido del campo de colectores, el calor requerido por el proceso y la energía auxiliar requerida (Venegas-Reyes, Ortega-Avila, Rodríguez-Muñoz, et al., 2019). Para estudiar el desempeño térmico de una planta de generación eléctrica a base de vapor, se empleó el sistema de inferencia artificial neuro-difusa (ANFIS), el cual permite generar un conjunto de datos térmicos y energéticos asociados a la planta. Los resultados muestran que ANFIS es capaz de crear modelos de inteligencia artificial sin la necesidad de contar con expertos en el área de estudio para la obtención de los datos difusos que mejor representen el problema analizado (Sayyaadi & Baghsheikhi, 2019). Esta herramienta también permite llevar a cabo análisis exergéticos, económicos, asignación de costos exergéticos y balance de costos exergoeconómicos para sistemas energéticos (Sayyaadi & Baghsheikhi, 2018).

Una de las herramientas de inteligencia artificial con mayor utilidad en el área de las energías renovables son las redes neuronales artificiales (ANN, por sus siglas en inglés), las cuales han demostrado ser adecuadas para la modelación y estudio de sistemas energéticos. En cuanto a las aplicaciones relacionadas con la energía solar, las ANN permiten calcular la cantidad de vapor entregado por un generador solar, modelar el comportamiento de sistemas de calentamiento solar de agua y de sistemas fotovoltaicos, predecir la radiación solar, entre otras (Kalogirou, 2001; Kalogirou, 2013). A través de tecnologías basadas en ANN, máquinas de vectores soporte (SVM, por sus siglas en inglés)

y conjuntos de árboles de regresión, es posible estimar la temperatura de operación de módulos fotovoltaicos (May Tzuc, Bassam, Mendez-Monroy, & Sanchez Dominguez, 2018). La regresión de vectores soporte (SVR, por sus siglas en inglés), la regresión del proceso gaussiano (GPR, por sus siglas en inglés) y las ANN son herramientas que permiten estimar la generación de energía solar y eólica en determinada ubicación, así como la demanda energética de los usuarios a la red; siendo la ANN aquella que predice con menor margen de error la demanda a la red (Sharifzadeh, Sikinioti-Lock, & Shah, 2019). En el aspecto ambiental, las ANN han permitido estimar el índice de partículas  $PM_{10}$  y  $PM_{2.5}$  concentradas en el aire, empleando una red formada por 30 neuronas en la capa oculta y empleando el método de optimización de Levenberg-Marquardt (Espinosa Guzmán, May Tzuc, Balam Pantí, et al., 2017).

Las distintas herramientas de inteligencia artificial mencionadas anteriormente permiten crear modelos que describen con precisión los fenómenos observados en la naturaleza. Sin embargo, en muchas ocasiones la etapa de modelación representa únicamente un paso intermedio necesario para obtener la optimización de los resultados, a partir de los parámetros de diseño del problema. El diagrama de Pareto se presenta como una herramienta auxiliar asociada al proceso de optimización, el cual permite visualizar en dos dimensiones el espacio en donde se encuentra el conjunto de soluciones óptimas del fenómeno estudiado.

En trabajos previos, el diagrama de Pareto ha permitido obtener la región de soluciones óptimas al momento de querer maximizar la eficiencia exergética y minimizar el costo total nivelado y el costo del impacto ambiental de un sistema de cogeneración termodinámico conocido como CGAM (Sayyaadi, 2009). Con el fin de incrementar la viabilidad económica de los SHIP, se ha estudiado la hibridación de sistemas fotovoltaicos con colectores solares planos, analizando a través del diagrama de Pareto la minimización del costo total, así como del costo nivelado de energía teniendo como restricción al factor de capacidad (Starke, Cardemil, Escobar, & Colle, 2018).

Debido a que el diagrama de Pareto presenta un vector de soluciones óptimas para cada variable de salida asociada al modelo estudiado, es necesario contar con un criterio que permita elegir dentro de estos vectores, al conjunto de soluciones optimizadas que satisfagan los objetivos planteados por el investigador. Estos objetivos deben estar definidos previamente a la creación del modelo de inteligencia artificial, además de presentar una relación inversa con respecto a los parámetros de diseño del fenómeno; esto debido a que, en caso contrario, no sería necesario contar con un criterio de selección, sino que bastaría con llevar los parámetros de diseño al valor mínimo o máximo permitido, según sea el caso. Este análisis realizado posterior a la obtención de las soluciones óptimas es referido a menudo como herramientas o técnicas para la toma de decisiones multiobjetivo y ha permitido el surgimiento de distintas técnicas empleadas en la literatura, en función de la naturaleza de los objetivos considerados.

Recientemente, se ha desarrollado una herramienta de toma de decisión multicriterio con el nombre de DAIRYMOO por sus siglas en inglés (*Dairy Multi-Objective Optimization*), enfocada exclusivamente a optimizar el desempeño económico y ambiental de las granjas. Esta herramienta es de utilidad para los granjeros así como para los creadores de políticas afines, ya que les permite optimizar el uso de equipos, modificar prácticas y tarifas eléctricas en las granjas (Breen, Murphy, & Upton, 2019). También se han desarrollado técnicas que permiten tomar decisiones multicriterio en el ámbito automovilístico (Castro & Parreiras, 2018). Además de los mencionados anteriormente, existen muchos métodos de toma de decisión multiobjetivo presentes en la literatura (Czyzak, Slowinski, Danev, et al., 1990; Abido, 2003; Sianaki, Masoum, & Potdar, 2017). En el ámbito energético, estos métodos se han empleado para estimar ahorros energéticos, así como la reducción de emisiones contaminantes (Cui, Geng, Zhu, & Han, 2017).

En trabajos previos llevados a cabo en México, se ha evaluado el desempeño ambiental y energético, así como la rentabilidad de una planta termosolar de uso industrial basadas en concentradores parabólicos a pequeña escala, empleando diagramas de Pareto y la Técnica de Preferencia de Orden por Similitud a la Solución Ideal (TOPSIS, por sus siglas en inglés), como herramientas para la toma de decisiones multiobjetivo (May Tzuc, 2020).



Estas herramientas permiten conocer la región de soluciones óptimas al comparar dos o más variables, para posteriormente encontrar la solución particular dentro de dicha región la cual se ubique lo más cerca posible de la solución ideal.

El presente trabajo empleará una metodología basada en colectores solares planos, inteligencia artificial para la creación de modelos sustitutos y algoritmos de optimización con el propósito de aprovechar la radiación global y optimizar los indicadores económicos y ambientales del sistema SHIP.

## **Justificación**

En la actualidad, las industrias a nivel internacional están buscando maneras de continuar con la generación de productos demandados por la sociedad, disminuyendo el impacto ambiental que implican los procesos para la obtención de dichos productos. Debido a la gran demanda de calor por parte de estos procesos, la conversión de energía solar a energía térmica se presenta como una opción atractiva ante esta apremiante tarea. El Plan Nacional de Desarrollo (PND) 2019-2024, en el apartado de rescate del sector energético, establece una nueva política energética que impulsará el desarrollo sostenible mediante la producción de energía con fuentes renovables. Además, el PND pugna por una transición energética que alentará la reindustrialización del país (PND, 2019).

Las tecnologías que permiten llevar a cabo esta transformación de energía reducen de manera significativa el impacto ambiental; dentro de las más empleadas a nivel internacional, destacan los colectores solares de placa plana, colectores solares parabólicos y colectores lineales de Fresnel. Sin embargo, debido a que el aspecto económico es uno de los pilares para que el sector industrial se mantenga y crezca, la implementación de estas tecnologías no puede realizarse sustituyendo por completo las formas tradicionales para la obtención de energía térmica. Esto debido a que los dispositivos industriales que aprovechan la energía solar aún se encuentran en desarrollo y mejoramiento, lo que las convierte en costosas, al compararlas con aquellas tradicionales que emplean combustibles fósiles. Por tal motivo, es importante lograr la implementación de sistemas híbridos en la industria, permitiendo de esta manera la incorporación de sistemas que permitan la

reducción de gases contaminantes y se mantengan en el margen de lo económico y energéticamente viable. Los colectores de placa plana se presentan como la tecnología de aprovechamiento de energía solar más económica del mercado (Sharma A. K., Sharma, Mullick, & Kandpal, 2017), alcanzando las temperaturas demandadas por determinadas industrias alrededor del mundo; específicamente, por el proceso de pasteurización requerido en la industria láctea (Mekhilef, Saidur, & Safari, 2011; Kumar, Hasanuzzaman, & Rahim, 2019).

Para llevar a cabo la implementación de esta tecnología, es necesario contar con el recurso solar para la conversión energética. México es un país caracterizado por los altos niveles de radiación solar recibidos a lo largo del año, contando con una insolación solar que llega a los  $8.5 \text{ kWh/m}^2$  al día en los estados ubicados al norte del país (Ramos, Ramirez, & Beltran, 2014; Pérez-Denicia, Fernández-Luqueño, Vilariño-Ayala, 2017). Además, es el país con mayor número de centrales de energía térmica encargadas de brindar calor solar a distintos procesos industriales (INTEC, 2020). Por tal motivo, es apremiante la necesidad de realizar estudios en las industrias que ya cuentan con esta tecnología, así como aquellas que planean realizarlo, ya sea en México o cualquier otro país que cuente con el recurso solar apropiado. En estos análisis se incluyen indicadores como el Valor Presente Neto (VPN), Costo Total del Ciclo de Vida (TLCC) y Mitigación de Gases de Efecto Invernadero (ACM), a través de los cuales es posible conocer la configuración tecnológica óptima del sistema SHIP la cual ofrece los mayores beneficios económicos, energéticos y ambientales.

Debido a que los procesos industriales que demandan calor frecuentemente operan de manera continua, no es viable llevar a cabo los estudios mencionados anteriormente de forma aplicada; unos minutos de inactividad pueden causar pérdidas económicas significativas. Por tal motivo, la creación de modelos teóricos que describan los procesos asociados al sistema SHIP es indispensable para realizar este tipo de análisis. Las herramientas computacionales, fundamentadas en la inteligencia artificial desarrollada en los últimos años, permiten obtener predicciones de sistemas energéticos con un margen de error significativamente pequeño. A través de estas herramientas, es posible estudiar y predecir el comportamiento térmico y energético de las plantas encargadas de brindar SHIP,

ahorrando tiempo y proyectando los beneficios energéticos, económicos y ambientales de estos sistemas a largo plazo.

Basado en lo mencionado anteriormente, el presente trabajo propone una metodología computacional para ayudar a la integración sostenible de la tecnología fototérmica en los procesos industriales del sector lácteo. A través de un enfoque de optimización multiobjetivo, se pretende mejorar el diseño y operabilidad de los sistemas SHIP. En este trabajo se desarrolla un estudio económico-ambiental para la incorporación de un sistema SHIP basado en colectores solares planos en la industria láctea en México, empleando herramientas de optimización y toma de decisiones multiobjetivo.

## **Hipótesis**

La implementación de una metodología computacional basada en las herramientas de inteligencia artificial en la industria láctea mexicana permitirá establecer estrategias de operación para disminuir la emisión de gases contaminantes y mejorar el rendimiento, diseño, viabilidad económica de plantas termosolares basadas en colectores solares planos.

## **Objetivo General**

Determinar la viabilidad de un campo de colectores solares planos en la industria láctea en México, considerando distintos tipos de clima y optimizando parámetros económicos, energéticos y ambientales de la planta industrial.

## **Objetivos específicos**

- i) Modelar el comportamiento térmico y energético de un colector solar plano.
- ii) Diseñar una planta industrial considerando las condiciones energéticas necesarias para llevar a cabo el proceso de pasteurización.
- iii) Integrar un campo de colectores solares planos dentro de la planta industrial, para suministrar parte de la energía requerida.
- iv) Obtener las condiciones térmicas del campo de colectores solares planos para optimizar los parámetros económicos, energéticos y ambientales de la planta industrial.

## Capítulo 1. Calor solar para el proceso industrial

El calor es un recurso empleado por la humanidad desde los principios de su existencia. Desde usos sencillos como la calefacción de hogares hasta labores que demandan mayor complejidad en el sector industrial, tales como el procesamiento de alimentos o fundición de metales, este recurso es empleado a lo largo del mundo para distintos fines. A partir de la aplicación para la cual sea empleado, corresponde un rango de temperatura necesario para poder llevar a cabo este proceso. Actualmente, el calor es utilizado en distintos procesos industriales, cada uno con su curva de demanda de calor característica a lo largo del tiempo. Estos procesos suelen clasificarse como calor de baja temperatura ( $< 150\text{ }^{\circ}\text{C}$ ), calor de mediana temperatura ( $150\text{ }^{\circ}\text{C} - 400\text{ }^{\circ}\text{C}$ ) y calor de alta temperatura ( $> 400\text{ }^{\circ}\text{C}$ ) (Solar Payback, 2018). Los procesos industriales más significativos se muestran en la Tabla 1.1, junto con su respectiva demanda de temperatura. De esta tabla se observa que los procesos donde existen transformaciones químicas, así como la industria del plástico, son los que presentan una demanda de calor con los rangos de temperatura más altos; mientras que, en los sectores industriales de alimentos y bebidas, las temperaturas que se requieren asociadas a los distintos procesos se encuentran dentro de los rangos más bajos reportados en la literatura (IRENA, 2015).

**Tabla 1.1** Procesos industriales y sus demandas de temperatura (IRENA, 2015)

<b>Sector industrial</b>	<b>Proceso</b>	<b>Rango de temperatura [<math>^{\circ}\text{C}</math>]</b>
Alimentos	Secado	30-90
	Lavado	60-90
	Pasteurización	60-80
	Hervir	95-105
	Esterilización	110-120
	Tratamiento con calor	40-60
Bebidas	Lavado	60-80
	Esterilización	60-90
	Pasteurización	60-70
Papel	Cocinado y secado	60-80
	Agua para la caldera	60-90

	Blanqueamiento	130-150
Superficie metálica	Tratamiento, galvanoplastia	30-80
Ladrillos y bloques	Curación	60-140
	Blanqueamiento	60-100
	Tintura	70-90
Textil	Secado, desengrasado	100-130
	Lavado	40-80
	Fijación	160-180
	Prensado	80-100
	Jabones	200-260
Química	Caucho sintético	150-200
	Procesamiento de calor	120-180
	Pre calentamiento de agua	60-90
	Preparación	120-140
	Destilación	140-150
Plástico	Separación	200-220
	Extensión	140-160
	Secado	180-200
	Mezclado	120-140
Subproductos de harina	Esterilización	60-90
	Pre calentamiento de agua para la caldera	30-100
Otros sectores industriales	Enfriamiento solar industrial	55-180
	Calefacción de fábricas	30-80

---

Las temperaturas mencionadas en la Tabla 1.1 habitualmente son alcanzadas a través de medios de generación de calor no renovables, empleando la energía proveniente de los combustibles fósiles. Sin embargo, es posible satisfacer esta demanda térmica mediante el aprovechamiento de la energía solar, reduciendo el impacto negativo de los procesos industriales sobre el medio ambiente. Para ello, es necesario aplicar distintas tecnologías

capaces de aprovechar este recurso renovable, considerando el rango de temperaturas que se desea satisfacer.

## 1.1 Tecnología solar térmica aplicada a la industria

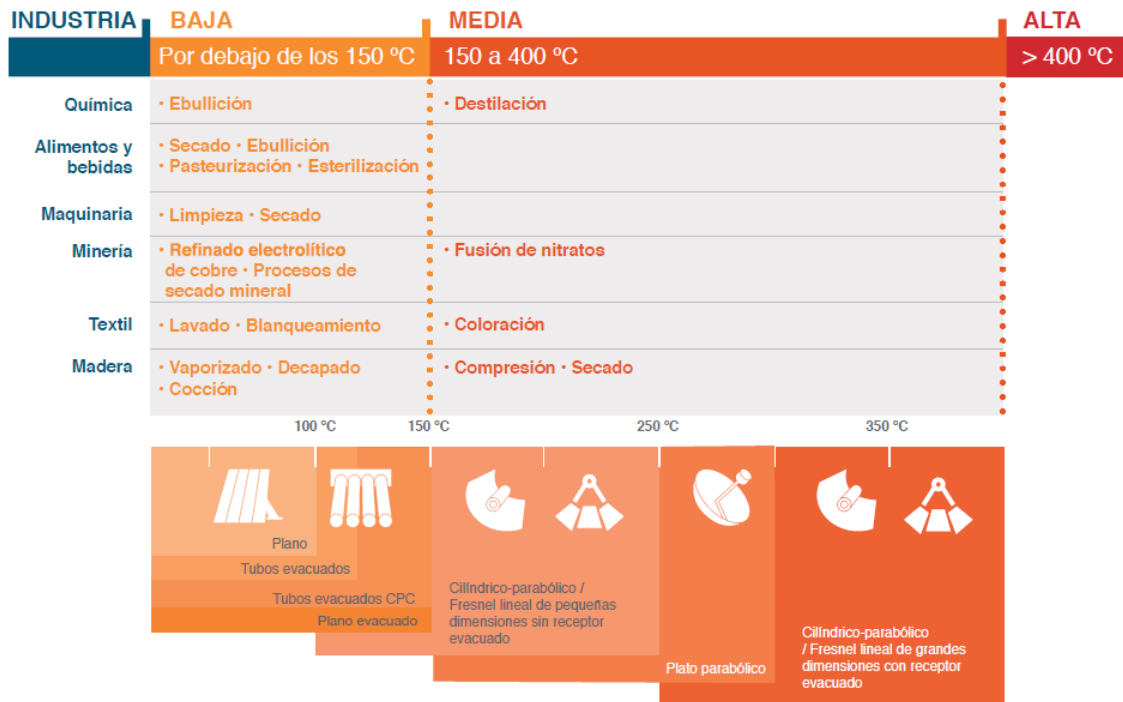
Existen distintas tecnologías capaces de entregar calor dentro de los rangos de temperatura mencionadas en la Tabla 1.1, aprovechando exclusivamente la energía del sol. De acuerdo a la forma en que se orientan hacia el sol, éstas pueden clasificarse como estacionarias, de seguimiento con un eje y de seguimiento con dos ejes. En relación al tipo de absorbedor que emplean para captar la radiación solar, éste puede ser plano, tubular o concentrado en un punto. Finalmente, la razón de concentración está dada por el cociente entre el área de apertura y el área de absorción o recepción del colector. En la Tabla 1.2 se clasifican los distintos tipos de colectores solares en función de los parámetros anteriores, así como el rango de temperaturas que entregan. En esta tabla se observa que, a medida que la tecnología asociada al colector solar se vuelve más compleja, comenzando por sistemas estacionarios hasta llegar a mecanismos de seguimiento solar con dos ejes, el rango de temperaturas que dicha tecnología es capaz de entregar aumenta. Esta relación directa también se presenta entre la razón de concentración y el rango de temperatura, mostrando que el incremento en la cantidad de radiación solar concentrada en el colector favorece el aumento de la temperatura asociada al calor entregado (Kalogirou S. A., 2009).

**Tabla 1.2** Clasificación de los colectores solares (Kalogirou S. A., 2009)

<b>Movimiento</b>	<b>Colector</b>	<b>Tipo de absorbedor</b>	<b>Razón de concentración</b>	<b>Rango de temperatura [°C]</b>
Estacionario	Colector solar de placa plana	Plano	1	30-90
	Colector de tubos evacuados	Plano	1	50-200
Seguimiento con un eje	Colector parabólico compuesto	Tubular	1-5	60-240

	Reflector lineal de Fresnel	Tubular	10-40	60-250
	Colector de canal cilíndrico	Tubular	15-50	60-300
	Colector de canal parabólico	Tubular	10-85	60-400
Seguimiento con dos ejes	Reflector de plato parabólico	Punto	600-2000	100-1500
	Colector de campo de helióstatos	Punto	300-1500	150-2000

Las tecnologías presentadas en la Tabla 1.2 también pueden ser clasificadas a partir del rango de temperatura, considerando la demanda de calor de los procesos industriales. En la Figura 1.1, se muestran algunos procesos industriales junto con la tecnología solar capaz de satisfacer su demanda térmica. De esta figura se observa que, para los procesos de baja demanda térmica, los cuales demandan calor a temperaturas por debajo de los 150 °C, los colectores solares planos y los de tubos evacuados son capaces de satisfacer dicha demanda; mientras que, para los procesos de demanda térmica media, asociados al calor con temperaturas entre los 150 °C y los 400 °C, todos los colectores cuya razón de concentración sea mayor a 1 de acuerdo a la Tabla 1.2 permiten entregar el calor requerido. La ebullición, esterilización y fermentación son algunos de los procesos industriales de demanda baja de calor, mientras que la destilación química y la coloración de textiles se encuentran en la clasificación de demanda media.



**Figura 1.1** Procesos industriales, demanda de calor y tecnología solar capaz de satisfacer dicha demanda (Solar Payback, 2018)

Cuando se analizan distintas tecnologías solares térmicas, se debe tener en cuenta que, al aumentar el rango de temperatura para el calor entregado, también lo hace el valor económico de la tecnología empleada. Este valor económico suele medirse en el costo por cada metro cuadrado de tecnología solar instalada y varía en función de la ubicación geográfica. En la Tabla 1.3, se presentan los costos por metro cuadrado para las tecnologías solares térmicas correspondientes a distintas partes del mundo. Debido a que cada país posee distintas características económicas, es importante considerar que este valor monetario asociado a la tecnología solar cambia en función de la región geográfica donde ésta sea instalada; además del carácter espacial, el costo por metro cuadrado también se ve afectado por el aspecto temporal, en donde se involucran factores como el desarrollo de la tecnología solar térmica, así como la disponibilidad de la materia prima. Además de las variaciones económicas en función de la región geográfica, en esta tabla se observa que el colector parabólico fijo en India, el colector parabólico compuesto en China y el colector de placa plana y de tubos evacuados en India presentan los menores costos por metro



cuadrado de las tecnologías respectivas; mientras que las tecnologías que alcanzan los costos más altos son el colector de canal parabólico en México, el colector parabólico compuesto y el reflector lineal de Fresnel en Europa (Sharma A. K., Sharma, Mullick, & Kandpal, Solar industrial process heating: A review, 2017).

**Tabla 1.3** Costos reportados para distintos colectores solares empleados en la industria (Sharma A. K., Sharma, Mullick, & Kandpal, 2017)

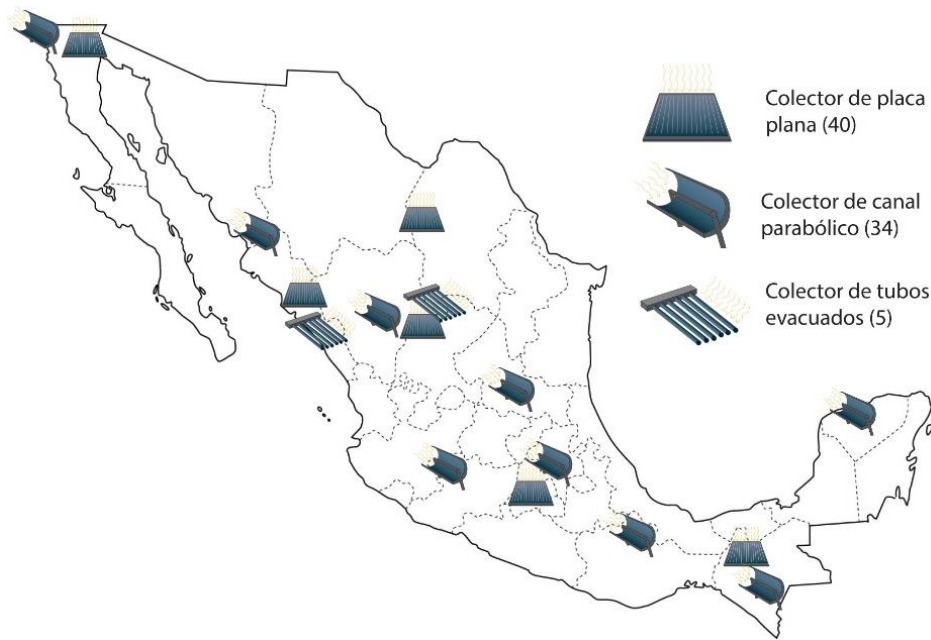
<b>Colector solar</b>	<b>País</b>	<b>Costo por <math>m^2</math> del colector [USD/m<sup>2</sup>]</b>
Colector de placa plana y colector de tubos evacuados	India	180
	China	130
Colector parabólico compuesto	Europa	450-900
	India	333
	India	113-300
Colector parabólico fijo	India	113-300
Colector parabólico con seguimiento	India	300-600
Colector de canal parabólico	Europa	650
	India	270-445
	México	400-629
Reflector lineal de Fresnel	Europa	690-900

Para llevar a cabo el proceso de pasteurización en una industria láctea, es necesario trabajar con temperaturas en el rango de 60 a 90 °C (Tabla 1.1). De acuerdo a la Tabla 1.3, una de las tecnologías más económica capaz de entregar temperaturas dentro de este rango son los colectores de placa plana. En la siguiente sección, se aborda esta tecnología considerando los principales usos que se le ha dado a nivel industrial en México.

## **1.2 Colectores solares de placa plana para calor solar en México**

Los colectores solares de placa plana pueden clasificarse según su uso final en residencial o industrial. Los residenciales permiten calentar el agua empleada en el aseo personal y en

los sistemas de lavado de ropa; mientras que los industriales brindan calor en los rangos de temperatura mostrados en la Tabla 1.1, de acuerdo al proceso involucrado. En la Figura 1.2 se observa que, en México, los colectores solares de placa plana son la tecnología más instalada, con 40 proyectos registrados hasta el momento; seguido de 34 instalaciones con colectores de canal parabólico y 5 que emplean concentradores de tubos evacuados, además de 4 que emplean otras tecnologías solares. A través de esta figura también es posible localizar las tecnologías mencionadas a lo largo del país; los concentradores de placa plana se ubican principalmente en la región noroeste, mientras que los concentradores parabólicos y de tubos evacuados están distribuidos en los estados del norte y centro de la república (AEE INTEC, 2020).



**Figura 1.2** Tecnología solar instalada a nivel nacional para brindar calor a procesos industriales (AEE INTEC, 2020).

Los colectores solares de placa plana han sido empleados en distintos ramos a nivel nacional, para brindar calor solar a procesos industriales (SHIP). En la Tabla 1.4 se presentan los principales ramos con mayor cobertura de proyectos SHIP. De esta tabla es posible observar que los subsectores industriales que presentan una mayor capacidad instalada de colectores solares de placa plana en México son los asociados a la manufactura

de productos (25.7 %), la producción de alimentos (23.2 %) y la industria farmacéutica (15.4 %). En cuanto a las características geográficas descritas en la tabla, se aprecia que la Ciudad de México es la entidad federativa con mayor cantidad de instalaciones y el tipo de clima predominante para el uso de este tipo de tecnología es el templado. Además, el promedio del volumen del tanque térmico, área del campo solar y carga térmica registrados hasta el momento son de  $26 m^3$ ,  $465.6 m^2$  y  $326.1 kW_{th}$ , respectivamente (AEE INTEC, 2020).

**Tabla 1.4** Capacidad instalada de los colectores solares de placa plana en México a partir del subsector industrial (AEE INTEC, 2020)

Subsector industrial	Capacidad instalada	Locación (año)	Rango térmico (°C)	Tipo clima	Tanque térmico ( $m^3$ )	Campo solar ( $m^2$ )	Carga térmica ( $kW_{th}$ )
Agricultura	5.1 %	Ciudad Juárez (2018)	60-75	Seco	9	200.0	140.0
		Zacatecas (2017)	70-85	Árido	12	125.0	87.0
Minería	12.8 %	Jalisco (2016)	No especificado	Templado	660	6380.0	4466.0
		Jalisco (2016)	No especificado	Templado	No especificado	6270.0	4400.0
		Durango (2012)	60-80	Seco	15	330.0	231.0
		Guerrero (2017)	60-70	Subtropical	3	60.0	42.0
		Guerrero (2017)	65-85	Subtropical	3	45.0	31.5
Manufactura de productos	25.7 %	Morelos (2016)	60-80	Árido	5	110.0	77.0
		Toluca (2011)	60-70	Templado	12	172.0	120.0
		Ciudad de México (2009)	60-70	Templado	4	64.0	45.0
		Ciudad de México (2007)	60-80	Templado	15	232.0	162.0
		Ciudad de México (2018)	65-80	Templado	3.5	72.0	50.4

		Ciudad de México (2018)	60-70	Templado	9	164.0	114.0
		Chiapas (2010)	90	Tropical	25	650.0	455.0
		Ciudad de México (2018)	70-85	Templado	5	70.0	49.0
		Sonora (2011)	55-75	Seco	7.5	240.0	168.0
		Morelos (2001)	55-85	Árido	20	450.0	315.0
		Baja California (2015)	65-70	Árido	3	65.0	45.5
		Baja California (2017)	55-85	Árido	5	175.0	122.5
		Coahuila (2013)	65-75	Seco	6	110.0	77.0
		Baja California (2009)	No especificado	Árido	5	100.0	70.0
Procesado de alimentos	23.2 %	Estado de México (2014)	65-85	Templado	5	125.0	87.5
		Ciudad de México (2010)	55-85	Templado	3	72.0	50.0
		Ciudad de México (2009)	60-70	Templado	3	56.0	39.0
		Ciudad de México (2018)	50-70	Templado	10	125.0	87.5
		Estado de México (2018)	50-75	Templado	2.5	45.0	31.5
Industria farmacéutica	15.4 %	Ciudad de México (2017)	60-70	Templado	1.5	30.0	21.0
		Ciudad de México (2015)	60-75	Templado	3	50.0	35.0

		Morelos (2011)	70-80	Templado	25	360.0	252.0
		Ciudad de México (2009)	55-75	Templado	8	154.0	107.0
		Morelos (2012)	60-75	Templado	20	525.0	367.0
		Estado de México (2018)	60-80	Templado	4	75.0	52.5
Industria metalúrgica y eléctrica	5.2 %	Ciudad de México (2004)	70-85	Templado	3.5	64.0	44.0
		Querétaro (2018)	60-90	Templado	2	24.0	16.8
Transporte	5.0 %	Estado de México (2019)	50-70	Templado	7	130.0	91.0
		Guanajuato (2018)	60-90	Templado	2	25.0	17.5
Investigación	7.6 %	Querétaro (2018)	60-80	Templado	4	80.0	56.0
		Morelos (2018)	70-95	Árido	Sin tanque	75.0	52.5
		Sinaloa (2018)	75-110	Seco	Sin tanque	60.0	42.0

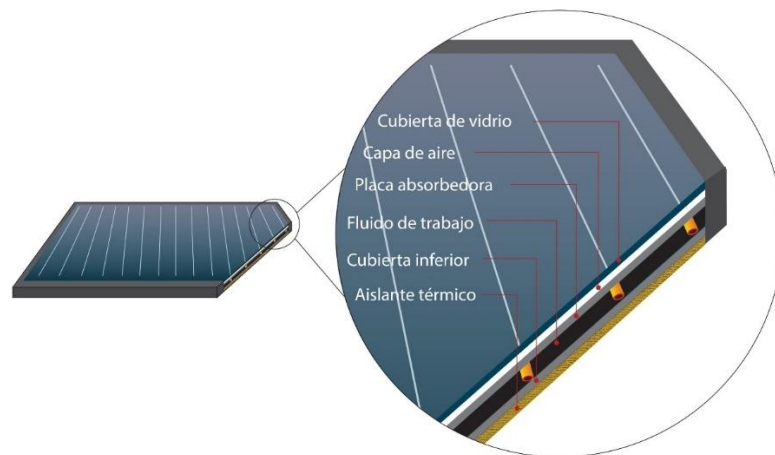
### 1.3 Características del colector solar de placa plana

Distintos sectores industriales han aprovechado una de las opciones de tecnología solar térmica más viables, desde el punto de vista económico y energético, para brindar calor solar a sus procesos. Antes de llevar a cabo la implementación de estos dispositivos en la industria, se requiere plantear las ecuaciones que los describen; la importancia de esta etapa radica en conocer las condiciones bajo las cuales es posible suministrar el calor demandado por el proceso industrial de manera parcial o total.

### 1.3.1 Balance de energía y ecuaciones gobernantes

Los colectores solares de placa plana están formados por una estructura hecha a partir de capas, en donde cada una de ellas cuenta con una función específica y necesaria para el aprovechamiento de la energía solar térmica (Cetina Quiñones, 2019). En la Figura 1.3 se presenta una vista transversal de las secciones que componen al colector solar:

- Cubierta de vidrio: La primera capa está formada por una cubierta de vidrio, la cual protege la estructura completa del dispositivo permitiendo a su vez el paso de la luz solar.
- Capa de aire y placa absorbedora: La segunda capa consiste en un espacio con aire, el cual funge como aislante, disminuyendo las pérdidas asociadas al calor absorbido por la tercera capa hacia el medio ambiente.
- Fluido de trabajo: Después del segmento absorbente, se presenta la tubería por donde circula el fluido de trabajo, cuya temperatura se ve modificada gracias a la energía recibida por la estructura previa.
- Cubierta inferior: Una cubierta es colocada como soporte en el bloque inferior a la tubería.
- Aislante térmico: Por último, se añade el aislante térmico como otro elemento que aporta a la disminución en las pérdidas energéticas.



**Figura 1.3** Principales componentes del colector solar plano considerados para el análisis energético.

Para estudiar el comportamiento térmico y energético del colector, es necesario realizar un balance energético del mismo, a través de todas las capas que lo conforman. La expresión para llevar a cabo este balance está dada por la ecuación:

$$\frac{dE}{dt} = \dot{Q}_i - \dot{Q}_o + \dot{Q}_g \quad (1.1)$$

Donde  $dE/dt$  es el cambio de energía interna a lo largo del tiempo, mientras que  $\dot{Q}_i$ ,  $\dot{Q}_o$  y  $\dot{Q}_g$  representan la cantidad de calor que entra, sale y se genera, respectivamente, dentro del sistema estudiado. Es importante mencionar que se estudia la aplicación del colector solar de placa plana bajo régimen estacionario, por lo que la ecuación (1.1) es igual a cero.

Para llevar a cabo el balance de energía sobre la cubierta de vidrio, se considera que el calor entrante a dicha cubierta es el recibido por la radiación solar; mientras que el calor de salida lo conforman la radiación que es transferida a la capa absorbente y la convección natural generada a partir de la capa de aire adyacente. Considerando este análisis, el balance energético para la primera cubierta está dada por la ecuación (1.2) (Cetina Quiñones, 2019):

$$U_t(T_{amb} - T_g) + h_{nc}^{conv}(T_p - T_g) + h_{g-p}^{rad}(T_p - T_g) + G_t\alpha_g = 0 \quad (1.2)$$

Donde:

- $\dot{Q}_i = G_t\alpha_g [W/m^2]$  es la radiación absorbida por la cubierta de vidrio.
- $\dot{Q}_o = U_t(T_g - T_{amb}) + h_{nc}^{conv}(T_g - T_p) + h_{g-p}^{rad}(T_g - T_p)$ 
  - $T_{amb}$ ,  $T_g$  y  $T_p$  [ $^{\circ}C$ ] son la temperatura ambiente, de la capa de vidrio y de la capa absorbidora, respectivamente.
  - $U_t [W/m^2 \cdot ^{\circ}C]$  es el coeficiente global de pérdidas de calor en la cubierta de vidrio.
  - $h_{nc}^{conv} [W/m^2 \cdot ^{\circ}C]$  es el coeficiente de transferencia de calor por convección, de la cubierta de vidrio a la capa de aire.

- $h_{g-p}^{rad}$  [ $W/m^2 \cdot ^\circ C$ ] es el coeficiente de transferencia de calor por radiación, de la cubierta de vidrio a la placa absorbadora.
- $\dot{Q}_g = 0$ .

Realizando un análisis análogo para la placa absorbadora, el calor de entrada es aquel asociado a la radiación transmitida por la cubierta de vidrio; mientras que el calor de salida se debe a la convección con la capa de aire por una parte y con el fluido de trabajo por otra, así como a través de la radiación que no es completamente absorbida y por lo tanto emitida de vuelta a la capa de vidrio. El balance energético para la placa absorbadora es presentado en la ecuación (1.3) (Cetina Quiñones, 2019):

$$h_{nc}^{conv}(T_g - T_p) + h_{p-g}^{rad}(T_g - T_p) + h_f^{conv}(T_f - T_p) + h_{p-b}^{rad}(T_b - T_p) + G_t \tau_g \alpha_g = 0 \quad (1.3)$$

Donde:

- $\dot{Q}_i = G_t \alpha_p \tau_g$  [ $W/m^2$ ] es la radiación transmitida por la cubierta de vidrio.
- $\dot{Q}_o = h_{nc}^{conv}(T_p - T_g) + h_{p-g}^{rad}(T_p - T_g) + h_f^{conv}(T_p - T_f) + h_{p-b}^{rad}(T_p - T_b)$ 
  - $T_f$  y  $T_b$  [ $^\circ C$ ] son la temperatura del fluido de trabajo y de la cubierta inferior, respectivamente.
  - $h_{nc}^{conv}$  [ $W/m^2 \cdot ^\circ C$ ] es el coeficiente de transferencia de calor por convección, de la placa absorbadora a la cubierta de aire.
  - $h_{p-g}^{rad}$  [ $W/m^2 \cdot ^\circ C$ ] es el coeficiente de transferencia de calor por radiación, de la placa absorbadora a la cubierta de vidrio.
  - $h_f^{conv}$  [ $W/m^2 \cdot ^\circ C$ ] es el coeficiente de transferencia de calor por convección, de la placa absorbadora al fluido de trabajo.
  - $h_{p-b}^{rad}$  [ $W/m^2 \cdot ^\circ C$ ] es el coeficiente de transferencia de calor por radiación, de la placa absorbadora a la cubierta inferior.
- $\dot{Q}_g = 0$ .



Para la capa donde se encuentra el fluido de trabajo, es necesario considerar un flujo másico presente a lo largo de las tuberías donde circula. El cambio en la energía del fluido de trabajo está asociado a los balances térmicos previamente realizados, como se muestra en la ecuación (1.4) (Cetina Quiñones, 2019):

$$h_f^{conv}(T_p - T_f) + h_f^{conv}(T_b - T_f) = \dot{q} \quad (1.4)$$

Donde  $\dot{q}$  [ $W/m^2$ ] es la ganancia de calor del fluido de trabajo en términos de la longitud del colector, dado por la expresión (Vargas-López, y otros, 2018):

$$\dot{q} = \frac{\dot{m}_f c_{p,f}}{\gamma WL} (T_f - T_{f,in}) \quad (1.5)$$

En la ecuación anterior,  $T_{f,in}$  es la temperatura del fluido de trabajo a la entrada del colector. Sustituyendo en la ecuación (1.4), se obtiene el balance energético para el fluido de trabajo:

$$h_f^{conv}(T_p - T_f) + h_f^{conv}(T_b - T_f) = \Gamma(T_f - T_{f,in}) \quad (1.6)$$

Donde:

- $\dot{Q}_i = 0$ .
- $\dot{Q}_o = h_f^{conv}(T_f - T_p) + h_f^{conv}(T_f - T_b)$
- $\dot{Q}_g = 0$ .
- $\Gamma = \frac{\dot{m}_f c_{p,f}}{\gamma WL}$ 
  - $\dot{m}_f$  [ $kg/s$ ] es el flujo másico del fluido de trabajo.
  - $c_{p,f}$  [ $J/kg \cdot ^\circ C$ ] es el calor específico del fluido de trabajo.
  - $\gamma$  [–] es el parámetro de ganancia de calor del fluido de trabajo. Este valor engloba todas las formas de transferencia de calor experimentadas por el fluido a lo largo del ciclo de trabajo. De acuerdo a investigaciones previas, se sugiere un valor de 0.75 (Hirunlabh, Kongduang, Namprakai, & Khedari, 1999).
  - $W$  y  $L$  [ $m$ ] son el ancho y largo del colector solar plano, respectivamente.

- $\Gamma$  [-] es la razón entre la energía del fluido de trabajo y el área del colector solar plano.

Por último, la cubierta inferior emite calor en forma de convección hacia el fluido de trabajo y por radiación a la placa absorbadora; además, existen pérdidas al medio ambiente debido a la transferencia de calor existente en la superficie inferior del colector. El balance energético para esta capa está dado por la ecuación (1.7) (Cetina Quiñones, 2019):

$$h_{b-p}^{rad}(T_p - T_b) + h_f^{conv}(T_f - T_b) + U_b(T_{amb} - T_b) = 0 \quad (1.7)$$

Donde:

- $\dot{Q}_i = 0$ .
- $\dot{Q}_o = h_{b-p}^{rad}(T_b - T_p) + h_f^{conv}(T_b - T_f) + U_b(T_b - T_{amb})$ 
  - $h_{b-p}^{rad}$  [ $W/m^2 \cdot ^\circ C$ ] es el coeficiente de transferencia de calor por radiación, de la cubierta inferior a la placa absorbadora.
  - $U_b$  [ $W/m^2 \cdot ^\circ C$ ] es el coeficiente global de pérdidas de calor en la cubierta inferior.
- $\dot{Q}_g = 0$ .

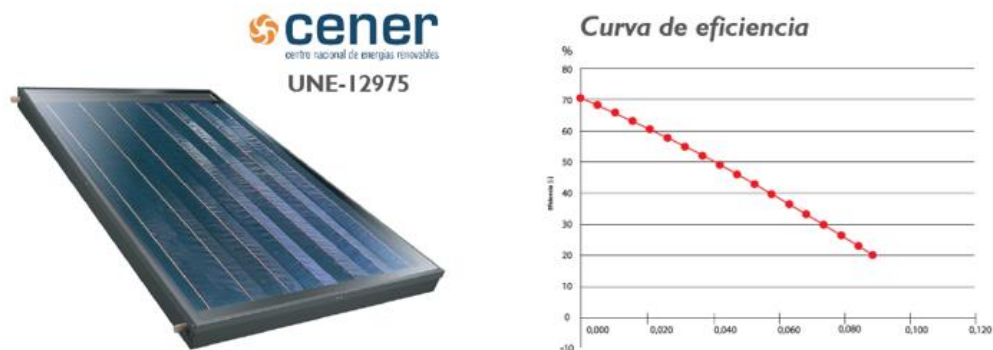
El sistema de ecuaciones que gobiernan el desempeño del colector solar de placa plana está dado por la matriz (Cetina Quiñones, 2019):

$$\begin{pmatrix} (h_{nc}^{conv} + h_{p-g}^{rad} + U_t) & -(h_{nc}^{conv} + h_{p-g}^{rad}) & 0 & 0 \\ -(h_{nc}^{conv} + h_{p-g}^{rad}) & (h_{nc}^{conv} + h_{p-g}^{rad} + h_f^{conv} + h_{p-b}^{rad}) & -h_f^{conv} & -h_{p-b}^{rad} \\ 0 & -h_f^{conv} & (2h_f^{conv} + \Gamma) & -h_f^{conv} \\ 0 & -h_{p-b}^{rad} & -h_f^{conv} & (h_{p-b}^{rad} + h_f^{conv} + U_b) \end{pmatrix} \begin{pmatrix} T_g \\ T_p \\ T_f \\ T_b \end{pmatrix} = \begin{pmatrix} U_t T_{amb} + \alpha_g G_t \\ \alpha_p \tau_g G_t \\ \Gamma T_{f,in} \\ U_b T_{amb} \end{pmatrix} \quad (1.8)$$

### 1.3.2 Tecnología comercial

En México, la instalación de la tecnología solar térmica a nivel industrial ha sido impulsada gracias a empresas que han favorecido la integración de dichos dispositivos al mercado, a través de estrategias de financiamiento atractivas construidas a partir de indicadores económicos sólidos proyectados a lo largo de la vida útil del proyecto. La inclusión de los colectores solares de placa plana en el sector industrial mexicano se ha debido en gran parte a la empresa Módulo Solar, la cual cuenta con el 95 % de las instalaciones correspondientes a este tipo de tecnología a nivel nacional (AEE INTEC, 2020).

Este estudio emplea el Colector Solar MS 1.9 UE (Figura 1.4), fabricado por la empresa Módulo Solar. Este colector fue elegido debido a que presenta las características necesarias para operar a nivel industrial; entre las más importantes destacan el uso de la superficie selectiva BLUE alemana, aislamiento de poliuretano inyectado y una cubierta de vidrio templado. Además, este colector se encuentra certificado por la Secretaría de Energía (SENER) de acuerdo a la norma europea UNE-12975 (Módulo Solar, 2019).




**Figura 1.4** Colector solar MS 1.9 UE de dimensiones 2045 x 931 mm y 31.6 kg, con su respectiva curva de eficiencia (Módulo Solar, 2019).

Las dimensiones del Colector Solar MS 1.9 UE, así como las propiedades físicas de sus componentes son incluidos en el modelo creado previamente a partir de las ecuaciones gobernantes del dispositivo. Este modelo correspondiente a un colector solar plano es empleado para estudiar la implementación de un campo de estos dispositivos al proceso industrial de fermentación láctea.

## 1.4 Descripción y análisis del sistema SHIP

Existen elementos indispensables que se deben tomar en cuenta al momento de integrar la tecnología solar a un proceso industrial, los cuales son: campo de colectores solares, medio de almacenamiento térmico, circuito hidráulico, elementos de recirculación, calentador auxiliar y sistema de monitoreo y control. Otros parámetros a tomar en cuenta son la cantidad de energía térmica que debe satisfacer el sistema SHIP, la temperatura en la cual el fluido portador de calor interactúa en el intercambiador de calor y el propósito por el cual el fluido será calentado, ya sea producción de agua caliente o generación de vapor (May Tzuc, 2020).

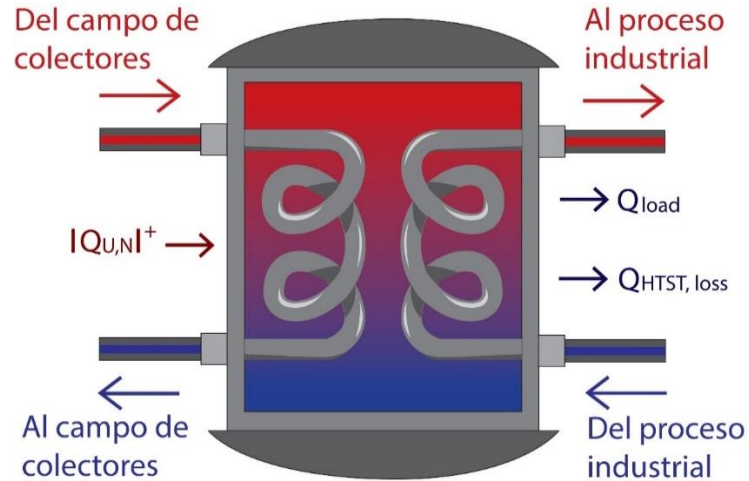
La posición que ocupa el calentador auxiliar dentro del sistema SHIP está en función del rango térmico que pretende entregar la tecnología solar empleada. Cuando el calentador auxiliar se encuentra en paralelo (Figura 1.5a), la tecnología solar debe ser dimensionada de tal forma que satisfaga por completo la demanda térmica del proceso industrial. Por otra parte, cuando el calentador está conectado en serie (Figura 1.5b), éste permite calentar aún más el fluido proveniente de la tecnología solar, en caso de ser necesario, para satisfacer la demanda térmica.



**Figura 1.5** Sistema industrial con calor solar integrado. (a) cuenta con la configuración del calentador auxiliar en paralelo y (b) en serie (Kalogirou S. A., 2009).

De acuerdo al análisis anterior, el sistema SHIP con calentador auxiliar en serie es la configuración más favorable al momento de emplear colectores solares de placa plana, ya que permite aumentar la temperatura del fluido en caso de ser necesario. En la Figura 1.6

se representa el análisis térmico del sistema SHIP, considerando al intercambiador como volumen de control.



**Figura 1.6** Análisis térmico del volumen de control asociado al sistema SHIP.

La conservación de energía en el volumen de control se representa a través de la ecuación (Galindo-Luna, y otros, 2018):

$$V_{st}\rho_{st}CP_{st}\frac{dT_{st}}{dt} = |Q_{u,N}|^+ - Q_{load} - Q_{HTST,loss} \quad (1.9)$$

Donde  $|Q_{u,N}|^+$  [ $W/m^2$ ] es la ganancia térmica aportada por el campo solar,  $Q_{load}$  y  $Q_{HTST,loss}$  [ $W/m^2$ ] es la energía cedida a la demanda del proceso industrial y al medio ambiente, respectivamente.  $V_{st}$  [ $m^3$ ],  $\rho_{st}$  [ $kg/m^3$ ] y  $CP_{st}$  [ $J/kg \cdot ^\circ C$ ] son las propiedades del fluido ubicado en el tanque de almacenamiento térmico: volumen, densidad y calor específico. La energía demandada por el proceso industrial está dada por:

$$Q_{load} = \varepsilon_L(\dot{m}_L CP_{tf})(T_{st} - T_{mu}) \quad (1.10)$$

Donde  $\varepsilon_L$  [–] es la eficiencia del intercambiador de calor,  $\dot{m}_L$  [ $kg/s$ ] y  $CP_{tf}$  [ $J/kg \cdot ^\circ C$ ] el flujo másico y el calor específico del fluido empleado en la carga térmica y  $T_{st}$  y  $T_{mu}$  [ $^\circ C$ ] la temperatura en el tanque de almacenamiento y aquella que sale del campo de colectores

solares e ingresa al tanque. En cuanto al otro factor negativo de la ecuación (1.9), la pérdida energética del tanque de almacenamiento se obtiene de la expresión:

$$Q_{HTST,loss} = (UA)_{st}(T_{st} - T_a) \quad (1.11)$$

Con  $(UA)_{st}$  [ $W/m^2 \cdot ^\circ C$ ] el coeficiente de pérdida energética del tanque y  $T_a$  [ $^\circ C$ ] la temperatura ambiente. Cuando el campo solar no es capaz de generar la energía demandada por el proceso industrial, el calentador auxiliar entrega una energía que puede ser representada como:

$$Q_{aux} = |\varepsilon_L(\dot{m}_L C P_{tf})(T_{in} - \varepsilon_L T_{st} - T_{mu}(1 - \varepsilon_L))|^+ \quad (1.12)$$

Donde  $T_{in}$  [ $^\circ C$ ] es la temperatura de la carga térmica correspondiente al proceso industrial. Finalmente, la ganancia térmica  $|Q_{u,N}|^+$  [ $W/m^2$ ] para un campo de colectores solares de placa plana es obtenida mediante la ecuación:

$$|Q_{u,N}|^+ = A_a F_R (G_b \tau_{\alpha'} - U_L' (T_i - T_a)) \quad (1.13)$$

Donde  $A_a$  [ $m^2$ ] es el área unitaria del colector de placa plana,  $F_R$  [–] el factor de remoción de calor,  $G_b$  [ $W/m^2$ ] es la radiación solar global,  $\tau_{\alpha'}$  [–] el parámetro que relaciona la transmisividad de la cubierta con la absorptividad de la placa absorbadora del colector,  $U_L'$  [ $W/m^2 \cdot ^\circ C$ ] es la eficiencia óptica modificada y  $T_i$  [ $^\circ C$ ] es la temperatura inicial a la entrada del colector.

## 1.5 Indicadores de viabilidad económica y ambiental para el sistema SHIP

Una vez obtenidas las ecuaciones que gobiernan tanto el comportamiento térmico como energético del colector solar de placa plana, es necesario considerar indicadores que permitan evaluar el desempeño económico y ambiental resultante de la aplicación del campo de colectores sobre la industria láctea. En las siguientes subsecciones se presenta el desarrollo correspondiente para cada uno de éstos.

### 1.5.1 Indicador de viabilidad económica: NPV

El Valor Presente Neto (NPV, por sus siglas en inglés) es el parámetro que permite evaluar las características económicas del proyecto y decidir sobre la factibilidad de inversión sobre el mismo (Short, Packey, & Holt, 1995). Adaptando la fórmula de este indicador al presente trabajo, el NPV consiste en la diferencia económica entre la inversión inicial y la suma de flujos de efectivo a lo largo de la vida útil del proyecto.

$$NPV = -I_o + \sum_{i=1}^n \frac{FE_i}{(1 + td)^i} \quad (1.14)$$

Donde  $I_o$  es la inversión inicial,  $n$  es la vida útil del proyecto,  $td$  es la tasa de descuento anual y  $FE_i$  es el flujo de efectivo anual el cual considera la energía ahorrada debido a la implementación del campo de colectores solares ( $EA_i$ ), los costos de operación y mantenimiento ( $OM_i$ ) y el costo de la energía correspondiente al calentador auxiliar ( $ECA_i$ ):

$$FE_i = EA_i - OM_i - ECA_i \quad (1.15)$$

Donde:

$$EA_i = E_{th} PC_F (1 + ti_F)^i \quad (1.16)$$

$$OM_i = OM (1 + ti_{OM})^i \quad (1.17)$$

$$ECA_i = E_{aux} PC_F (1 + ti_F)^i \quad (1.18)$$

Donde  $E_{th}$  es la energía generada por el campo solar,  $PC_F$  el precio del combustible para el calentador auxiliar,  $OM$  el costo de operación y mantenimiento del primer año,  $E_{aux}$  la energía generada por el calentador auxiliar,  $ti_F$  la tasa de inflación del combustible y  $ti_{OM}$  la tasa de aumento anual de operación y mantenimiento. Un NPV positivo indica que la inversión es adecuada, mientras que valores negativos significan que la inversión inicial es mayor al rendimiento, por lo que el proyecto se rechaza (May Tzuc, 2020).

## 1.5.2 Indicador de viabilidad económica: TLCC

El segundo indicador de viabilidad económica es el Costo Total del Ciclo de Vida (TLCC, por sus siglas en inglés), el cual se presenta como un complemento al NPV. Este parámetro permite evaluar todas las salidas de efectivo necesarias para el correcto funcionamiento del proyecto durante el tiempo de vida del mismo (May Tzuc, 2020). En la ecuación (1.19) se presenta la ecuación correspondiente para su cálculo:

$$TLCC = I_o + \sum_{i=1}^n \frac{CT_i}{(1 + td)^i} \quad (1.19)$$

Donde  $CT_i$  son los costos totales a lo largo de la vida útil del proyecto, calculado como:

$$CT_i = OM_i - ECA_i \quad (1.20)$$

Los costos relacionados a la implementación del sistema SHIP con colectores solares de placa plana son reportados en la Tabla 1.5. Cabe mencionar que el valor asociado al concepto de operación y mantenimiento inicial es el 0.5 % de la inversión inicial  $I_o$ .

**Tabla 1.5** Parámetros económicos considerados para el sistema de calor solar implementado en el mercado mexicano.

Concepto	Valor	Referencia
<i>Costos de inversión</i>		
Costo de CPP instalado	\$280 USD/m <sup>2</sup>	(Ortega, 2018)
Costo de tanque de almacenamiento	\$1,020 USD/m <sup>3</sup>	(Ortega, 2018)
Operación y mantenimiento inicial	0.5 %	(Sharma A. K., Sharma, Mullick, & Kandpal, 2018)
<i>Costos de operación y mantenimiento</i>		
Tasa anual de operación y mantenimiento	5.0 %	(Ortega, 2018)
Tasa anual de costo de combustible	9.0 %	(SENER, 2018)
Tasa anual de descuento del proyecto	10.0 %	(Short, Packey, & Holt, 1995)
Vida útil del proyecto termosolar	20 años	(Short, Packey, & Holt, 1995)



*Costos del sistema auxiliar*

Diésel	\$0.1044 USD/kWh	(CRE, 2017)
Combustóleo	\$0.0428 USD/kWh	(CRE, 2017)
Gas LP	\$0.0760 USD/kWh	(CRE, 2017)
Gas natural	\$0.0186 USD/kWh	(CRE, 2017)

**1.5.3 Indicador de viabilidad ambiental: ACM**

La reducción de gases contaminantes a la atmósfera, principalmente dióxido de carbono, es una de las ventajas inherentes a la implementación de tecnología solar para brindar calor solar a un proceso industrial. El ACM es el indicador empleado para medir la reducción en la emisión de estos gases, a partir del cálculo reportado por el Instituto Mexicano de Ecología y Cambio Climático (INECC, 2014) en la ecuación (1.21):

$$ACM = \left[ \frac{44.01}{12.01} E_{th} \right] \left[ \frac{CC_F}{(CV_F)(\eta_F)} \right] \quad (1.21)$$

Donde 44.01/12.01 es el coeficiente estequiométrico para la oxidación total de carbono,  $CC_F$  es el contenido de carbono del combustible,  $CV_F$  es el valor específico del combustible y  $\eta_F$  es la eficiencia de la caldera de respaldo. Para considerar el uso de distintos combustibles en el calentador auxiliar, es necesario tomar en cuenta los parámetros ambientales presentados en la Tabla 1.6.

**Tabla 1.6** Características ambientales de los combustibles considerados para el sistema de calefacción de respaldo (INECC, 2014)

<b>Combustible</b>	<b>Densidad [kg/L]</b>	<b>Contenido de carbono [kg · C/kg<sub>FL</sub>]</b>	<b>Valor calorífico [kWh · kg<sub>FL</sub>]</b>
Diésel	0.826	0.8583	11.994
Combustóleo	0.999	0.8460	10.842
Gas LP	0.525	0.8199	12.822
Gas natural	0.844	0.7116	12.983

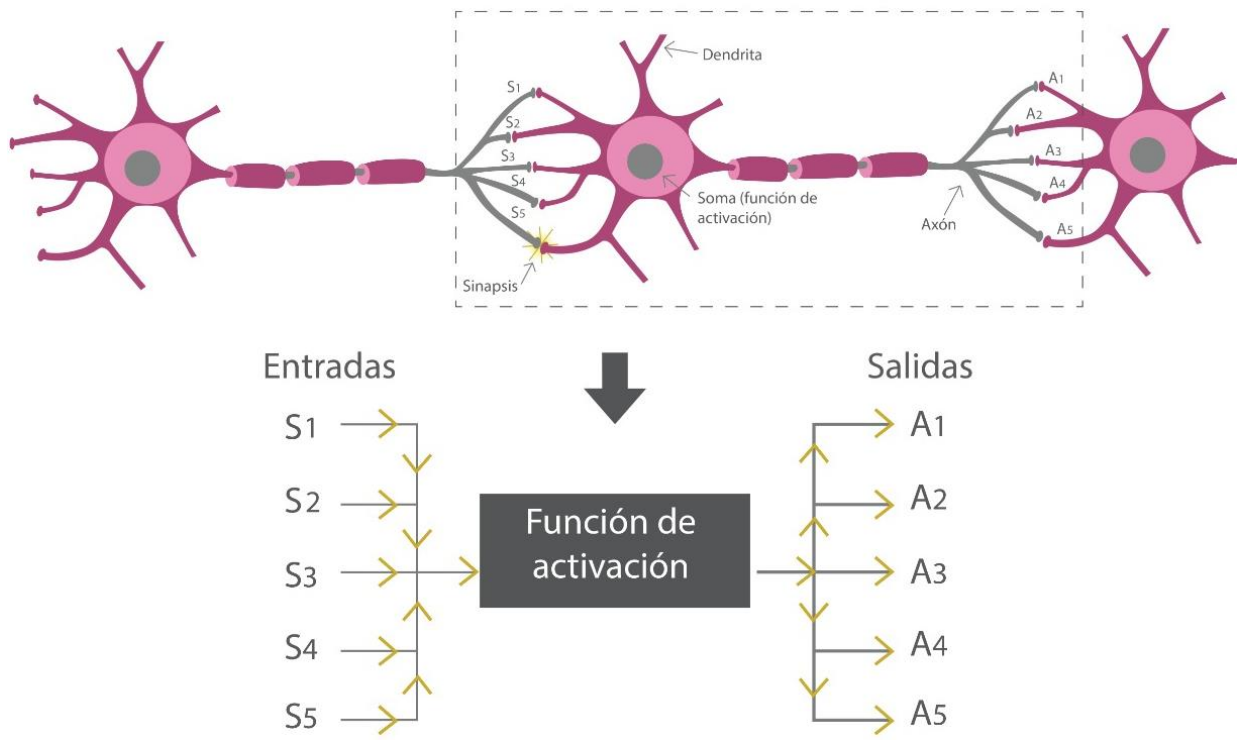
## **Capítulo 2. Herramientas computacionales avanzadas**

En distintas áreas de investigación, las herramientas que ofrece la inteligencia artificial en la actualidad han contribuido al desarrollo de la humanidad; principalmente a través del manejo y procesamiento de grandes cantidades de datos, sector que ha presentado un crecimiento constante durante los últimos 10 años. Una de las herramientas que ofrece la inteligencia artificial más empleadas en la actualidad son las redes neuronales artificiales, las cuales permiten representar fenómenos complejos a través de estructuras computacionales asociadas entre ellas de la misma manera que lo hacen las neuronas en el cerebro humano. Sin embargo, no basta con crear modelos asociados a los fenómenos estudiados; es necesario conocer cuáles son los parámetros involucrados en dichos sistemas, los cuales son capaces de optimizar los resultados deseados. En las siguientes secciones, se abordan las redes neuronales artificiales como herramienta para la modelación computacional, así como los algoritmos genéticos, enjambre de partículas y optimización de ballenas, metodologías desarrolladas para la obtención de los parámetros óptimos correspondientes al modelo estudiado.

### **2.1 Redes neuronales artificiales**

Debido a la facilidad para sintetizar el funcionamiento de sistemas complejos y aprender a través de valores previamente conocidos, las redes neuronales artificiales se presentan como una poderosa solución ante la tarea de procesar grandes cantidades de datos. Basando su comportamiento en la forma como las neuronas se conectan entre sí en el cerebro humano, esta herramienta de inteligencia artificial posee como unidad básica la neurona artificial (Romero, Dafonte, Gómez, & Ponousal, 2014). En la Figura 2.1a se representa una neurona con las partes que son significativas para el presente trabajo: Se le conoce como sinapsis a la conexión de entrada entre una neurona y otra, soma es el espacio físico donde se encuentra el núcleo de la neurona y axón es la terminal de salida para la neurona. La Figura 2.1b es la síntesis de cada una de estas partes a través de una neurona artificial. En esta neurona artificial, pueden existir múltiples entradas (sinapsis) y salidas


(axón con múltiples ramificaciones), así como una función de activación, ubicada representativamente en el soma, la cual determina el proceso de transformación que seguirá la señal eléctrica una vez que entra a dicha neurona (May Tzuc, 2020).



**Figura 2.1** Representación de las partes de una neurona y su analogía con una neurona artificial.

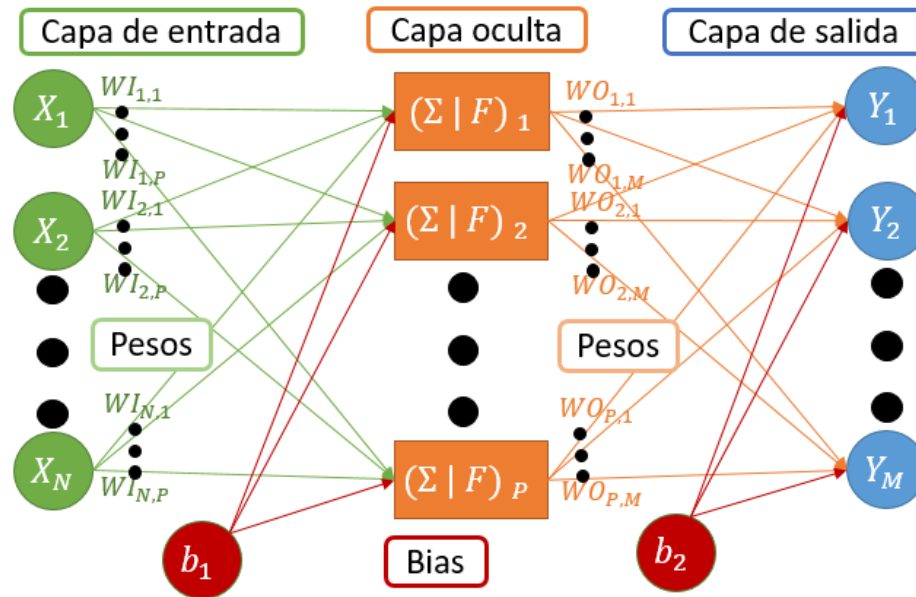
Al conjunto de estas neuronas con sus respectivos componentes se le conoce como red neuronal artificial (Figura 2.2). En ocasiones, es posible contar con neuronas que se encuentran ocultas entre las neuronas de entrada y salida; estas neuronas ocultas pueden formar una o más capas y sirven para optimizar el proceso de aprendizaje de la red neuronal artificial. Para llevar a cabo el proceso de aprendizaje en una red neuronal artificial, es necesario tener con un conjunto de variables de entrada para el cual ya se conozca la relación que guarda con el conjunto de las variables de salida. Tomando estos datos conocidos para las variables de entrada y salida, se les divide en tres grupos: aprendizaje, validación y prueba. En primera instancia, las variables de entrada y salida pertenecientes al grupo de aprendizaje son ingresadas a la red neuronal, para que ésta pueda crear una relación entre estas variables, la cual es medida a través de distintos parámetros

estadísticos. Posteriormente entra el grupo de validación, el cual permite comparar el desempeño estadístico obtenido hasta ahora por la red neuronal artificial con este nuevo conjunto de datos. El grupo de validación sirve para evitar el sobre entrenamiento de la red, que ocurre cuando ésta se especializa sobre un conjunto limitado de entradas y salidas. Por último, el grupo de prueba evalúa la calidad del modelo creado, al compararlo con datos que no formaron parte de los dos grupos anteriores (Gandomi, Alavi, & Ryan, 2015).



**Figura 2.2** Representación esquemática de una red neuronal artificial (Kalogirou S. , 2001)

Al momento de estudiar el funcionamiento de una red neuronal artificial, es necesario conocer la función que cumplen los pesos, bias y funciones de activación. En la Figura 2.3 se muestra un diagrama en donde se integran dichos componentes; cada uno de los elementos que entran a la neurona  $(x_1, x_2, \dots, x_N)$  posee un peso sináptico  $(WI_{1,1}, WI_{1,2}, \dots, WI_{N,P})$ , el cual determina la importancia que tiene cada una de estas variables de entrada con los valores obtenidos a la salida de la neurona  $(y_1, y_2, \dots, y_M)$ . Después de asociar los elementos de entrada con sus respectivos pesos sinápticos  $(\Sigma)$ , es necesario sumarle a este número el bias  $(b_1, b_2)$ , quien actúa como un factor de corrección. La cantidad obtenida entra a la función de activación  $(F)$ , para finalmente obtener los valores de salida (Viñuela & León, 2004).



**Figura 2.3** Principales elementos que componen una red neuronal artificial.

En cuanto a las funciones de activación, éstas pueden ser modificadas en función de la naturaleza del problema que se pretende resolver. Considerando a  $n$  como el valor de entrada a la función de transferencia, algunas de las más empleadas son la función logística sigmoide (Ecuación 2.1), tangente sigmoide (Ecuación 2.2) y lineal (Ecuación 2.3) (Haykin, 2008).

$$a = \frac{1}{1 + \exp(-n)} \quad 0 \leq a \leq 1 \quad (2.1)$$

$$a = \frac{2}{1 + \exp(-2n)} - 1 \quad -1 \leq a \leq 1 \quad (2.2)$$

$$a = n \quad -\infty \leq a \leq \infty \quad (2.3)$$

La herramienta de inteligencia artificial descrita permite crear modelos sustitutos de fenómenos presentes en la naturaleza. Sin embargo, es necesario contar también con técnicas que permitan llevar a cabo un análisis de las soluciones obtenidas, considerando las funciones y variables independientes que hayan sido empleadas para el entrenamiento de la red.

## 2.2 Optimización multiobjetivo

Los problemas de optimización siempre se han presentado como un reto en las distintas áreas de la ciencia. Considerando el número de funciones objetivo que posea el problema, éstos pueden clasificarse en optimización simple y optimización de objetivo múltiple, siendo éstos últimos los más frecuentes en la naturaleza. Los problemas en donde se requieren optimizar múltiples objetivos pueden ser representados a partir de las siguientes ecuaciones (Cui, Geng, Zhu, & Han, 2017):

$$\min(Y) = F(X) = [f_1(X), f_2(X), \dots, f_M(X)] \quad (2.4)$$

La ecuación 2.4 se encuentra condicionada por:

$$x_n^{\min} \leq x_n \leq x_n^{\max} \quad (2.5)$$

$$X = [x_1, x_2, \dots, x_N] \quad (2.6)$$

$$Y = [y_1, y_2, \dots, y_M] \quad (2.7)$$

De las ecuaciones anteriores,  $M$  es el número de funciones objetivo a optimizar,  $N$  es la dimensión del espacio donde se encuentran las soluciones el cual se encuentra limitado por los mínimos y máximos establecidos en la ecuación 2.5. El objetivo de resolver un problema de optimización multiobjetivo consiste en encontrar el conjunto de soluciones  $X$  que minimicen o maximicen, según sea el caso, las funciones establecidas en  $Y$ .

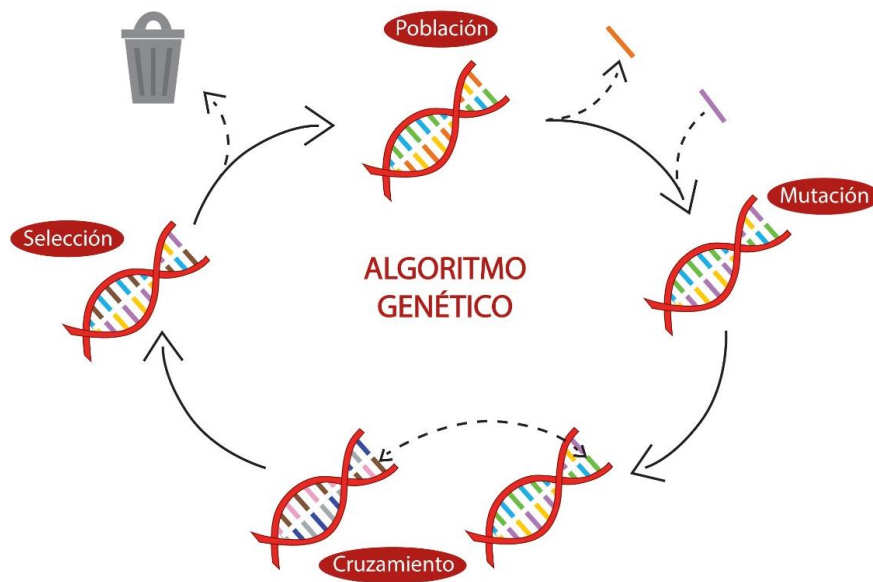
Debido a que, en este tipo de problemas las funciones objetivo tienden a estar en conflicto entre ellas, ocasionando que la solución de una no garantice la solución de las demás, se vuelve indispensable el estudio de técnicas que permitan encontrar el conjunto de soluciones óptimas adecuadas al problema (Cui, Geng, Zhu, & Han, 2017). Una de estas técnicas es el diagrama de Pareto, el cual consiste en un espacio en dos dimensiones donde se crea una región con todas las soluciones obtenidas. A las soluciones localizadas en el borde o frontera de esta región se les conoce como soluciones no-dominadas, debido a que son mejores a las localizadas en el interior del diagrama en al menos uno de los objetivos. Aquellas soluciones que también son factibles y se encuentran dentro del diagrama se les

llama dominantes. Una vez trazado el diagrama de Pareto considerando las soluciones dominantes y no-dominantes, las regiones de interés dentro del mismo diagrama se encuentran ubicadas en los extremos, donde se localiza el conjunto de soluciones que minimizan (extremo izquierdo en el eje de las abscisas y extremo inferior en el eje de las ordenadas) o maximizan (extremo derecho en el eje de las abscisas y extremo superior en el eje de las ordenadas) las funciones objetivo (May Tzuc, 2020).

En las siguientes subsecciones, se presentan tres algoritmos capaces de obtener el conjunto de soluciones que dan forma al diagrama de Pareto, para problemas de optimización múltiple.

### **2.2.1 Algoritmo genético**

Los algoritmos genéticos (AG) son una de las herramientas de inteligencia artificial más empleadas, debido a que basan sus diseños en la evolución como un proceso de optimización inherente entre los individuos que conforman una población. Los principios básicos sobre los que trabaja cualquier AG son la evolución, la relación entre los cromosomas mediante la selección natural y la reproducción de los mejores individuos (Euskal Herriko Unibersitatea, 2019). El ciclo con los principales procesos anteriormente mencionados se muestra en la Figura 2.4. El algoritmo parte de una población inicial, donde algunos de sus elementos sufren una mutación al perder algunos componentes y recibir nuevos; la etapa de cruzamiento se lleva a cabo, al intercambiar elementos con otros individuos de la población. Después de estos procesos, se seleccionan los mejores individuos de la población inicial con base en parámetros establecidos en función del objeto de estudio; los individuos que satisfacen dichos criterios pasan a formar parte de la nueva población, mientras que los demás son desechados (Cook, Ragsdale, & Major, 2000).



**Figura 2.4** Principales etapas del algoritmo genético.

El procedimiento seguido por todos los AG mantiene los mismos principios: se inicia con individuos dentro de una población, donde cada uno es una solución del problema. Cuando se ejecuta el algoritmo, se llevan a cabo procesos de cruzamiento entre los mejores individuos, generando descendencia y en ocasiones mutaciones. La nueva generación de individuos vuelve a pasar por este proceso de cruzamiento y mutaciones hasta que los individuos obtenidos satisfagan el criterio de convergencia propio del problema (Gaspar Cunha, Takahashi, Henggeler Antunes, & Pereira, 2012). En la Figura 2.5 se presenta el pseudocódigo, en donde se incluyen los pasos descritos anteriormente.



```

Generar una población inicial  $P_0$  con  $n$  individuos
Definir la función  $OF$  para evaluar el desempeño de cada individuo
Establecer el criterio de convergencia  $CC$ , el cual debe cumplir  $OF$  para
finalizar el algoritmo
while no se cumpla el criterio de convergencia:  $OF(n) \neq CC$ 
  Crear una nueva población  $P_n$ 
    for (tamaño de  $P_n$ ) / 2
      Seleccionar dos individuos de la generación anterior:
       $P_n(n) = P_{n-1}(n-2)$ 
       $P_n(n-1) = P_{n-1}(n-3)$ 
      Cruzar los dos individuos seleccionados:
       $P_n(n) = \alpha P_n(n-1)$ 
       $P_n(n-1) = \beta P_n(n)$ 
      Mutar los dos descendientes obtenidos del cruzamiento:
       $P_n(n-2) = \gamma P_n(n) + \delta P_n(n-1)$ 
       $P_n(n-3) = \epsilon P_n(n) + \epsilon P_n(n-1)$ 
      Evaluar el desempeño de los descendientes mutados:
       $OF(P_n(n-2))$ 
       $OF(P_n(n-3))$ 
      Insertar los descendientes mutados en la nueva generación:
       $P_{n+1}(n) = P_n(n-2)$ 
       $P_{n+1}(n-1) = P_n(n-3)$ 
    end
  end

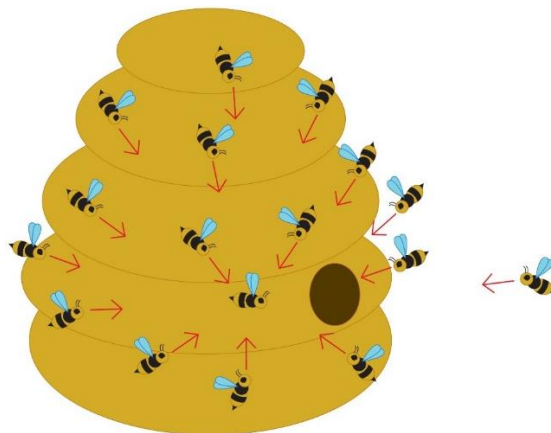
```

**Figura 2.5** Pseudocódigo para el algoritmo genético (Euskal Herriko Unibersitate, 2019)

Los elementos que comparten todos los AG son la población, así como los procesos de selección, cruzamiento y mutación. En la población, el tamaño y la diversidad son elementos clave; la diversidad es un parámetro para determinar la distancia que existe entre individuos, mientras que poblaciones de tamaño grande permite ampliar el espacio de búsqueda de la solución, al mismo tiempo que aumenta el tiempo de cómputo (The Mathworks Inc., 2014). En la selección, los métodos más empleados para llevar a cabo este proceso son ruleta, elitista y torneo. En la ruleta, se asigna una probabilidad a cada individuo en función de su aptitud, seleccionando aquellos con mayor probabilidad; elitista consiste en copiar algunos de los mejores individuos a la siguiente generación, permitiendo otro proceso de selección a los individuos restantes; mientras que torneo se basa en elegir individuos de forma aleatoria, elegir los de mayor aptitud para que se reproduzcan y su descendencia sustituya a los peores (Ponce Cruz, 2010). Por último, el cruzamiento puede ser destructivo cuando se inserta la descendencia a la nueva población, aunque no sea mejor a los padres, o no destructivo cuando la descendencia sólo sobrevive si es mejor a los padres. La mutación agrega diversidad a la población y favorece la generación de nuevos individuos; sin este proceso, el algoritmo sólo combinaría genes de la población inicial (The Mathworks Inc., 2014).

## 2.2.2 Algoritmo de enjambre de partículas

El algoritmo de enjambre de partículas es el más antiguo de los llamados algoritmos de enjambre, propuesto por Kennedy et al. en 1995 (Kennedy & Eberhart, 1995). La principal inspiración a partir de la cual se desarrolló este algoritmo fue el comportamiento social de los pájaros y peces. Este algoritmo se creó inicialmente para resolver problemas cuyas soluciones estuvieran representadas por puntos en un espacio multidimensional de búsqueda con valores continuos. Gracias a las modificaciones por las que ha pasado, actualmente es posible emplearlo para obtener soluciones irregulares o transitorias para problemas no diferenciables (Slowik, 2018). En la Figura 2.6 se muestra una representación visual del comportamiento característico seguido por los individuos que conforman una población, bajo el funcionamiento del algoritmo de enjambre de partículas. En cada iteración, cada individuo se encarga de buscar la solución óptima del problema estudiado; en este diagrama, la entrada a la colmena representa dicha solución. Una vez que al menos uno de estos individuos ha encontrado dicha solución, todos los demás actualizan su posición a partir de este individuo que ha dado con la misma; la localización de la nueva ubicación espacial a la cual deben desplazarse todos los demás individuos que no dieron con la solución óptima se encuentra representada por las flechas rojas. De esta manera, cada iteración acerca a todos los individuos de la población cada vez más a la solución óptima.



**Figura 2.6** Representación del comportamiento característico de los individuos sometidos al algoritmo de enjambre de partículas.

```

Determinar la función objetivo  $OF(\cdot)$  de dimensión  $H$ 
Establecer el criterio de convergencia  $CC$ , el cual debe cumplir  $OF(\cdot)$  para
finalizar el algoritmo
Determinar el rango de variabilidad para cada dimensión  $j$  de  $[P_{i,j}^{\min}, P_{i,j}^{\max}]$ 
Determinar los valores para el número de partículas en el enjambre ( $N$ ) y el
factor de aprendizaje ( $c_1$  y  $c_2$ )
Crear de forma aleatoria el enjambre  $P$ , el cual consiste en  $N$  partículas, donde
cada partícula es un vector de dimensión  $H$ :  $N = N(n_1, n_2, \dots, n_H)$ 
Crear el vector  $Gbest$  de dimensión  $H$ :  $Gbest = Gbest(g_1, g_2, \dots, g_H)$ 
for cada partícula  $P_i$  del enjambre  $P$ 
    Crear una partícula  $Pbest$  igual a la partícula  $P_i$ :  $Pbest = P_i$ 
    Crear una velocidad  $V_i$  para cada partícula  $P_i$ :  $V_i = V(P_i)$ 
    Evaluar la partícula  $P_i$  usando la función  $OF(\cdot)$ :  $OF_i = OF(P_i)$ 
    Asignar la mejor partícula  $P_i$  a  $Gbest$ :
        if  $OF(P_i) > OF(P_{i-1})$ 
             $Gbest = P_i$ 
        end if
end for
while no se cumpla la condición de finalización:  $OF(P_i) \neq CC$ 
    for cada partícula  $P_i$  del enjambre  $P$ 
        for cada dimensión  $j$ 
            Actualizar la velocidad usando la fórmula:
             $V_{i,j} = V_{i,j} + c_1 r_1 (Pbest_{i,j} - P_{i,j}) + c_2 r_2 (Gbest_j - P_{i,j})$ 
            Actualizar la partícula  $P_{i,j}$  usando la fórmula:
             $P_{i,j} = P_{i,j} + V_{i,j}$ 
            if  $P_{i,j} < P_j^{\min}$ 
                 $P_{i,j} = P_j^{\min}$ 
            end if
            if  $P_{i,j} > P_j^{\max}$ 
                 $P_{i,j} = P_j^{\max}$ 
            end if
        end for
        Evaluar la partícula  $P_i$  usando la función  $OF(\cdot)$ :  $OF(P_i)$ 
        if  $OF(P_i)$  es mejor que  $OF(Pbest_i)$ 
            Asignar  $P_i$  a  $Pbest_i$ :  $Pbest_i = P_i$ 
        end if
    end for
    Seleccionar la mejor partícula del enjambre  $P$  y asignarla a  $T$ :
     $T = Pbest_i$ 
    if  $OF(T)$  es mejor que  $OF(Gbest)$ 
        Asignar  $T$  a  $Gbest$ :  $Gbest = T$ 
    end if
end while
Imprimir  $Gbest$ 

```

**Figura 2.7** Pseudocódigo para el algoritmo de optimización de enjambre de partículas (Slowik, 2018)

En la Figura 2.7 se presenta el pseudocódigo para este algoritmo. A partir de esta Figura, es posible definir los siguientes pasos para la correcta ejecución del algoritmo (Slowik, 2018):

1. Antes de iniciar el proceso de optimización, es necesario haber definido las funciones objetivo  $OF$  y todos los parámetros del algoritmo como los coeficientes de aprendizaje  $c_1$  y  $c_2$  y el número de partículas  $N$ .

2. Se crea de forma aleatoria el enjambre  $P$ , formado por un número de partículas  $N$ . Cada partícula está representada por un vector de dimensión  $H$  y sus elementos particulares representan las variables de decisión de  $OF$ . Cada variable de decisión  $j$  está restringida por un valor mínimo  $P_j^{min}$  y un valor máximo  $P_j^{max}$ . Por lo que la partícula  $P_i$  es representada por el vector:

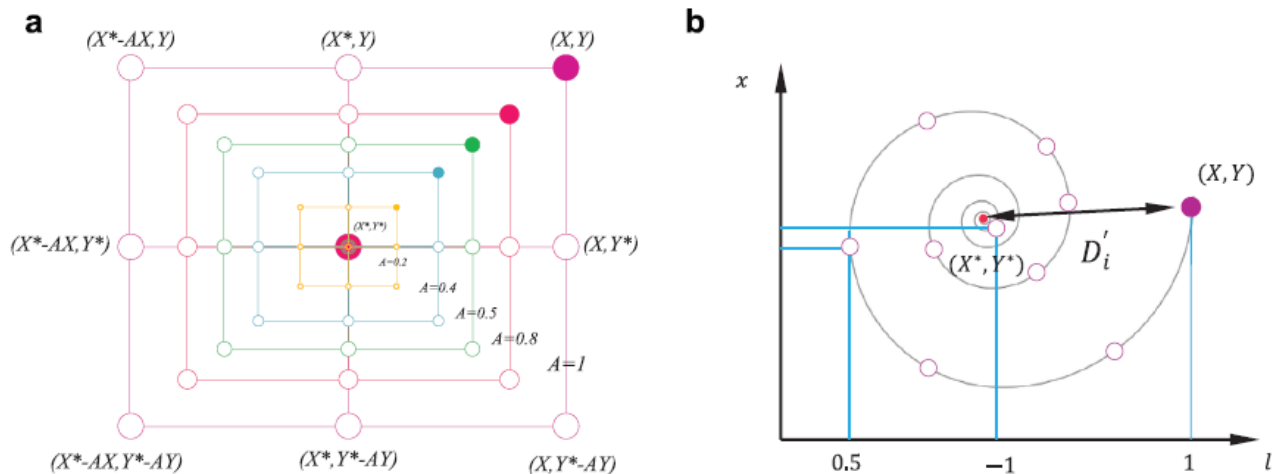
$$P_i = \{P_{i,1}, P_{i,2}, \dots, P_{i,D-1}, P_{i,D}\} \quad (2.9)$$

Donde  $P_{i,1}, P_{i,2}$  y así sucesivamente son los valores del rango  $[P_j^{min}, P_j^{max}]$ .

3. Se crea el vector  $Gbest$ , donde se almacena la mejor solución encontrada hasta el momento. También se crea  $Pbest_i$  de forma correspondiente para cada  $P_i$ . La partícula  $Pbest_i$  es igualada a  $P_i$ . En  $Pbest_i$  se almacena la mejor partícula  $P_i$  encontrada hasta el momento.
4. Se crea el vector  $V_i$  para la partícula  $P_i$ , consistiendo en un vector conformado únicamente por ceros. Cuando se crea el primer enjambre  $P$ , se evalúa la calidad de cada partícula usando  $OF$ . Después de la evaluación del enjambre, se selecciona la mejor partícula  $P_i$  que será almacenada en  $Gbest$ .
5. Se inicia el ciclo principal del algoritmo, hasta cumplir con el criterio de convergencia. Para todas las partículas en el enjambre  $P$ , se actualiza cada valor del vector velocidad  $V_i$  que es asignado a la partícula  $P_i$ . También se actualiza cada elemento de  $P_i$  usando valores del  $V_i$  previamente obtenido.
6. Una vez que  $P_i$  ha sido actualizada, se evalúa la calidad de esta partícula usando  $OF$ . Si  $OF(P_i)$  es menor a  $OF(Pbest_i)$  para el caso de un problema de minimización, entonces la partícula  $P_i$  es asignada a la correspondiente  $Pbest_i$ .
7. Cuando se han evaluado todas las partículas del enjambre  $P$ , entonces se selecciona a la mejor y se le asigna una partícula temporal  $T$ . Si el valor de  $OF(T)$  es menor que  $OF(Gbest_i)$ , entonces la partícula  $T$  será asignada a la partícula  $Gbest$ .
8. El algoritmo se repite hasta que se cumpla el criterio de convergencia. Cuando esto sucede, se devuelve el valor de la partícula  $Gbest$  como la solución del algoritmo.

### 2.2.3 Algoritmo de optimización de ballena

Este algoritmo fundamenta su operación en el comportamiento realizado por las ballenas al momento de cazar su alimento, que es el plancton ubicado en la superficie marina. En este caso, los individuos de la población están representados por las ballenas distribuidas en el espacio de búsqueda, el cual simboliza al océano por donde se desplazan dichos individuos. Existen principalmente dos etapas en las que se divide el proceso de búsqueda (Mirjalili & Lewis, 2016): en un primer momento, las ballenas o individuos de la población buscan sobre la superficie del mar el lugar en donde sea más probable encontrar el alimento o solución óptima del problema (Figura 2.8a). Una vez ubicado esa región espacial, el segundo paso consiste en sumergirse debajo del plancton, para subir describiendo un movimiento en espiral de contracción hasta converger en un punto, el cual es la solución óptima del problema (Figura 2.8b). Como en la mayoría de los algoritmos de optimización basados en el comportamiento presentado por un conjunto de animales, el objetivo principal consiste en reducir la distancia entre los individuos de búsqueda que existen en la población con respecto a la solución óptima.



**Figura 2.8** Descripción esquemática de las dos etapas en las que se divide el algoritmo de optimización de ballenas: a) Búsqueda superficial y b) Movimiento espiral de contracción (Mirjalili & Lewis, 2016)

La primera etapa está dictaminada por relaciones del tipo lineal entre los individuos, de tal forma que cada uno cubra de la mejor manera posible la totalidad del espacio. Mientras que

la segunda está gobernada por ecuaciones con movimiento circular, al llevar a cabo el ascenso a la superficie. Esto se puede observar en el pseudocódigo presentado en la Figura 2.9, en donde se describe el procedimiento empleado por este algoritmo, el cual inicia con una población  $n$  de ballenas como individuos de la población y establece la distancia a la solución óptima como parámetro de desempeño. Al iniciar con el proceso de búsqueda, se actualiza para cada individuo los parámetros descritos en las ecuaciones (Mirjalili & Lewis, 2016):

$$\vec{A} = 2\vec{a} \cdot \vec{r} - \vec{a} \quad (2.4)$$

$$\vec{C} = 2 \cdot \vec{r} \quad (2.5)$$

Donde  $\vec{a}$  es un vector que decrece linealmente de 2 a 0 a lo largo de las iteraciones para las dos etapas del proceso y  $\vec{r}$  es un vector aleatorio con valores entre 0 y 1. Además,  $\vec{A}$  y  $\vec{C}$  son los vectores coeficientes para las siguientes ecuaciones:

$$\vec{D} = |\vec{C}\vec{X}^*(k) - \vec{X}(k)| \quad (2.6)$$

$$\vec{X}(k+1) = \vec{X}^*(k) - \vec{A} \cdot \vec{D} \quad (2.7)$$

Donde  $\vec{D}$  es la distancia a la que se encuentra el agente de búsqueda respecto a la solución óptima,  $\vec{X}$  es el vector de posición,  $\vec{X}^*$  es el vector de posición de la mejor solución encontrada hasta el momento y  $k$  es el número de iteración. Cabe mencionar que el agente de búsqueda es aquel instrumento desarrollado dentro del algoritmo, el cual tiene por fin encontrar la mejor solución que satisfaga los criterios de convergencia; en el caso del algoritmo de ballenas, los agentes de búsqueda contruidos para encontrar esta solución guardan una relación análoga con las ballenas en el proceso de capturar el plancton que satisface sus necesidades alimenticias. El algoritmo emplea  $p$  como un número aleatorio entre 0 y 1, al igual que  $l$  entre -1 y 1, de tal forma que si  $p < 0.5$  y  $|A| < 1$ , se actualiza la posición del agente de búsqueda a través de la ecuación (2.6); mientras que si  $|A| \geq 1$ , se selecciona de forma aleatoria un agente de búsqueda y se actualiza su posición mediante

la ecuación (2.7). Para el caso de  $p \geq 0.5$ , la posición del agente de búsqueda es actualizada utilizando la ecuación (2.8):

$$\vec{X}(k+1) = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(k) \quad (2.8)$$

Donde  $b$  es una constante que define la forma del espiral logarítmico y  $\vec{D}'$  indica la distancia de la ballena  $i$ -ésima a la presa, dada por la ecuación (2.9):

$$\vec{D}' = |\vec{X}^*(k) - \vec{X}(k)| \quad (2.9)$$

Una vez actualizadas todas las posiciones de los agentes de búsqueda, el algoritmo corrige a los agentes que se hayan salido del espacio de búsqueda, calcula el parámetro de desempeño para todos y actualiza la posición de la presa, en caso que esta haya sido mejor a la obtenida en la iteración previa (Mirjalili & Lewis, 2016).

```

Inicializar la población de ballenas  $X_i$  ( $i = 1, 2, \dots, n$ )
Calcular el desempeño  $OF$  de cada agente de búsqueda  $X_i$ :  $OF(X_i)$ 
 $X^*$  = El mejor agente de búsqueda
while  $k <$  número máximo de iteraciones
  for cada agente de búsqueda
    Modificar aleatoriamente los vectores  $l$  y  $p$ :
       $l = [-1, 1]$ 
       $p = [0, 1]$ 
    Actualizar los valores de  $\vec{r}$ ,  $\vec{a}$ ,  $\vec{A}$  y  $\vec{C}$ :
       $\vec{r} = r\vec{r}$ ;  $r = [0, 1]$ 
       $\vec{a} = a\vec{a}$ ;  $a = [2, 0]$ 
       $\vec{A} = 2\vec{a} \cdot \vec{r} - \vec{a}$ 
       $\vec{C} = 2 \cdot \vec{r}$ 
    if  $p < 0.5$ 
      if  $|A| < 1$ 
        Actualizar la posición del agente de búsqueda actual:
           $\vec{D}' = |\vec{C}\vec{X}^*(k) - \vec{X}(k)|$ 
      else if  $|A| \geq 1$ 
        Seleccionar un agente de búsqueda aleatorio  $X_{rand}$ 
        Actualizar la posición del agente de búsqueda actual:
           $\vec{X}(k+1) = \vec{X}^*(k) - \vec{A} \cdot \vec{D}'$ 
      end if
    else if  $p \geq 0.5$ 
      Actualizar la posición del agente de búsqueda actual:
         $\vec{D}' = |\vec{X}^*(k) - \vec{X}(k)|$ 
         $\vec{X}(k+1) = \vec{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \vec{X}^*(k)$ 
    end if
  end for
  Calcular el desempeño de cada agente de búsqueda:  $OF(X_i)$ 
  Asignar  $X^*$  a la mejor solución:
  if  $OF(X_{i+1})$  es mejor que  $OF(X_i)$ 
     $X^* = X_{i+1}$ 
  end
end while
Imprimir  $X^*$ 

```

**Figura 2.9** Pseudocódigo para el algoritmo de optimización de ballenas (Mirjalili & Lewis, 2016)

## Capítulo 3. Metodología computacional

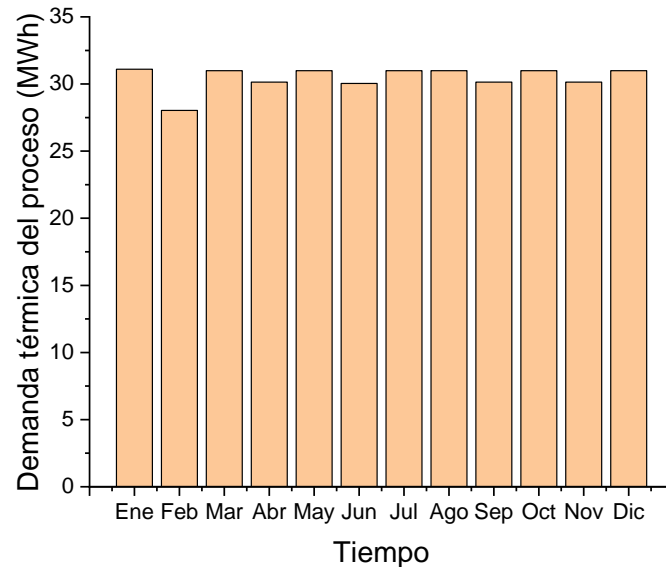
En este capítulo se presenta la metodología empleada para la optimización de los indicadores económico y ambiental para una planta industrial del sector lácteo mediante distintos algoritmos de optimización.

### 3.1 Descripción del caso de estudio

Como se observó en el capítulo 1, en México el sector de procesamiento de alimentos es uno de los principales consumidores de calor industrial (AEE INTEC, 2020). Dentro de ese sector, la industria láctea es una de las más importantes para el país, al contribuir con el 10% del producto interno bruto y colocar a México en la posición 8 respecto al nivel de producción láctea internacional (SADER, 2018). Además, el país cuenta con cuatro regiones climáticas específicas en donde la producción de leche se encuentra ubicada: región árida, seca, templada y tropical (SE, 2013).

El proceso industrial estudiado consiste en la pasteurización de la industria láctea, el cual demanda una energía térmica de 80-90 °C para llevar a cabo con éxito el tratamiento del producto lácteo (Lewis & Heppel, 2001). La planta opera de 9:00 horas a las 17:00 horas los 7 días de la semana, a fin de aprovechar la mayor radiación solar posible. La pasteurización requiere satisfacer  $125.00 \text{ kW}_{th}$ , con una demanda térmica de  $1,000 \text{ kW}_{th}$  por día; la demanda de la carga térmica y la tasa de flujo se consideran constantes a lo largo del año. La Figura 3.1 muestra la demanda térmica anual del proceso; se observa que ésta no presenta variaciones significativas entre cada mes, presentando un consumo total anual de 365 MWh.






**Figura 3.1** Demanda energética anual del proceso de pasteurización láctea.

El sistema para la generación de calor solar propuesto consiste en un campo de colectores solares de placa plana acoplados al proceso industrial descrito anteriormente. Dentro de los otros componentes presentes en el sistema, se encuentra un termo tanque central que permite almacenar la energía generada por el campo solar y proporcionarla al proceso industrial cuando ésta sea demandada. Las bombas centrífugas colocados en puntos estratégicos permiten circular el termo fluido, manteniendo el flujo de operación que requiere el proceso; mientras que la válvula de control de tres vías reduce la temperatura entregada al proceso cuando ésta exceda el valor demandado. Finalmente, un calentador auxiliar es conectado en serie para satisfacer la energía térmica faltante, cuando esto sea necesario.

En la Figura 3.2 se presenta un diagrama de los componentes antes mencionado, en donde se observan los dos circuitos o bucles principales que componen el sistema SHIP. En el primer circuito, la bomba P1 se activa cuando la radiación solar incidente sobre los colectores de placa plana supera los  $600 \text{ W/m}^2$  para circular el agua en el circuito termosolar (*Solar Thermal Circuit* o STC) y se desactiva cuando dicha radiación es menor o igual a  $400 \text{ W/m}^2$ . El segundo circuito, asociado a la carga térmica (*Thermal Load Circuit* o

TLC), se encarga de activar el sistema auxiliar cuando la temperatura que entra al proceso industrial ( $T_{in}$ ) es menor a la requerida, así como controlar la válvula de tres vías cuando  $T_{in}$  es mayor a la requerida. En la Tabla 3.1 se presentan los valores para los distintos componentes del sistema SHIP.



**Figura 3.2** Diagrama esquemático del sistema SHIP empleando colectores solares de placa plana.

Las características operativas del proceso industrial lácteo son presentadas en la Tabla 3.1. En ésta se consideran parámetros de diseño como el flujo másico del campo solar y la temperatura a la salida del mismo; es necesario considerar que estas condiciones deben cumplirse durante una jornada laboral de 8 horas, donde el calor es demandado de forma constante.

**Tabla 3.1** Características técnicas y operativas del sistema SHIP (May Tzuc, 2020)

Parámetros	Valores	Unidades
<i>Propiedades del fluido térmico</i>		
Calor específico	( $cp_{tf}$ ) 4180.0	[ $J \cdot kg^{-1} \cdot K^{-1}$ ]

Conductividad térmica	$(\kappa_{tf})$	0.670	$[W \cdot m^{-2} \cdot K]$
Viscosidad dinámica	$(\mu_{tf})$	0.00031	$[Pa \cdot s]$
Densidad	$(\rho_{tf})$	1000.0	$[kg \cdot m^{-3}]$

*Condiciones de operación del proceso industrial*

Temperatura de carga térmica	$(T_{in})$	90.0	$[^{\circ}C]$
Temperatura de retorno	$(T_{out})$	80.0	$[^{\circ}C]$
Calor de proceso requerido	$(Q_L)$	125.0	$[kW_{th}]$
Flujo másico del campo solar	$(\dot{m}_c)$	1.987	$[kg \cdot s^{-1}]$
Flujo másico de la carga térmica	$(\dot{m}_L)$	2.987	$[kg \cdot s^{-1}]$
Temperatura entrada campo solar	$(T_{i,N})$	90.0	$[^{\circ}C]$
Temperatura salida campo solar	$(T_{o,N})$	105.0	$[^{\circ}C]$
Horas diarias de trabajo	-	8	$[hrs]$
Eficiencia de la caldera	$(\eta)$	0.87	$[-]$

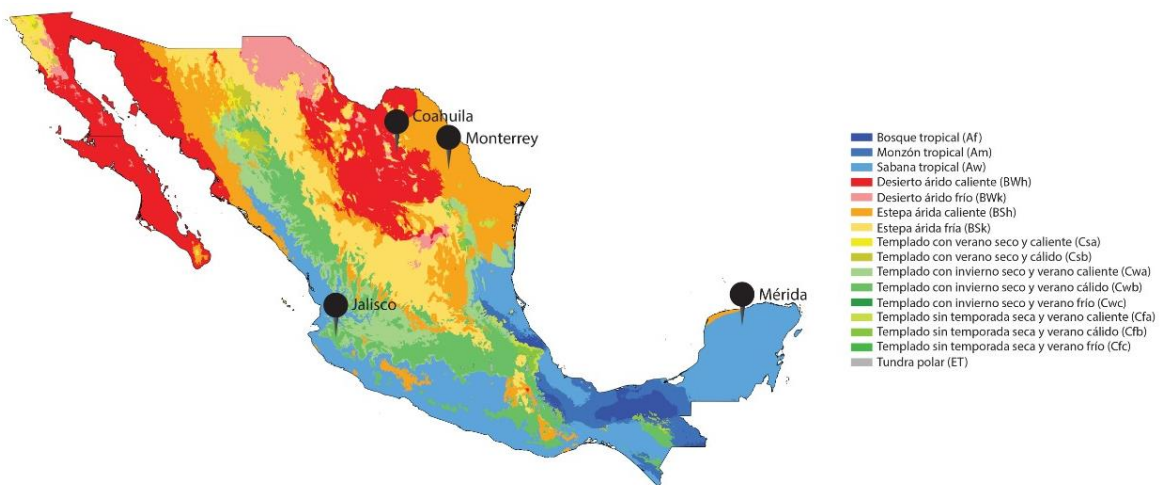
El campo solar térmico (*Solar Thermal Field* o STF) permite satisfacer una parte del calor demandado por la industria. El campo de colectores solares de placa plana fue modelado a partir del comportamiento térmico asociado a cada capa que compone este dispositivo (Cetina Quiñones, 2019). Dicho modelo fue validado al replicar la gráfica de eficiencia térmica (Figura 1.3) reportada por el fabricante en la ficha técnica (Módulo Solar, 2019); el procedimiento metodológico desarrollado en Matlab para llevar a cabo esta validación se encuentra en el Anexo 1.

Para almacenar la energía excedente y satisfacer la demanda en los momentos de radiación solar intermitente, se emplea un tanque térmico horizontal centralizado (*Horizontal Thermal Storage Tank* o HTST) hecho de acero inoxidable 304-2B en el interior y 304-BA en el exterior. El tanque cuenta con dos intercambiadores de calor para transportar la energía generada por el STF (HX1) al proceso industrial (HX2), sin que exista un contacto directo entre los dos circuitos. Las principales pérdidas térmicas de este elemento se deben a las

propiedades del material del tanque de agua caliente ( $UA_{st}$ ) y a la eficiencia de los intercambiadores de calor ( $\varepsilon_c$  y  $\varepsilon_L$ ).

En caso que la energía obtenida a partir de la radiación solar no sea suficiente para satisfacer la demanda térmica del proceso industrial, se emplea un sistema de calefacción convencional que funciona a partir de combustibles fósiles; esta fuente de calentamiento convencional permite además disminuir los costos iniciales asociados a la inversión del proyecto. Las pérdidas de energía correspondientes al calentador convencional se deben a la eficiencia del mismo ( $Q_{aux,loss}$ ) y a la transferencia de energía del sistema SHIP durante todo el proceso (May Tzuc, 2020).

Debido a que el sistema SHIP propuesto considera el recurso solar de la región donde es implementado, el análisis de distintas locaciones climáticas es indispensable a fin de evaluar el desempeño de los indicadores económico y ambiental. Las locaciones empleadas corresponden a los cuatro climas representativos que existen en el país: Coahuila representa el clima árido, Monterrey el clima seco, Jalisco el clima templado y Mérida el clima tropical (Figura 3.3). Las variables meteorológicas de interés obtenidas para cada clima son la radiación solar directa, la temperatura ambiente y la velocidad del viento. Estos datos fueron obtenidos de la base de datos climática del software SAM (Blair, y otros, 2014), considerando intervalos de 15 minutos.



**Figura 3.3** Mapa climático con la ubicación de los cuatro climas representativos seleccionados a nivel nacional.

### 3.2 Entrenamiento de la red neuronal artificial

Los modelos surrogados o sustitutos obtenidos mediante las distintas técnicas de inteligencia artificial permiten emular el comportamiento de sistemas complejos, reduciendo los esfuerzos computacionales y preservando una representatividad confiable del modelo original (Ascione, Bianco, De Stasio, Mauro, & Vanoli, 2017). Debido a la cantidad de parámetros térmicos, energéticos, económicos y ambientales manejados para cada una de las variables involucradas en el sistema SHIP, el modelo se vuelve computacionalmente costoso, con códigos extensos y subprogramas que dificultan el trabajo sobre el ciclo principal del sistema. Por tal motivo, en el presente trabajo se genera una base de datos de 22,464 datos obtenidos del sistema SHIP con el propósito de entrenar la red neuronal artificial (ANN) que se emplea como modelo sustituto. Los variables de entrada empleados para la ANN son el tipo de clima (CL), el combustible empleado para el sistema auxiliar de calor (FL), el volumen del tanque de almacenamiento térmico (VOL) y el área ocupada por el campo solar (ADS); mientras que los valores obtenidos para los indicadores económico y ambiental son empleados como parámetros de salida (ACM, NPV y TLCC). En la Tabla 3.2 se presentan los parámetros de entrada y salida con sus valores máximos, mínimos y nominales, así como sus respectivas unidades. Para FL la nomenclatura empleada es 1 diésel, 2 combustóleo, 3 gas LP y 4 gas natural; mientras que para CL se considera 1 como clima árido, 2 templado, 3 tropical y 4 seco.

**Tabla 3.2** Parámetros considerados para determinar la viabilidad económica y ambiental del sistema SHIP (May Tzuc, 2020)

<b>Parámetros</b>		<b>Máximo</b>	<b>Nominal</b>	<b>Mínimo</b>	<b>Unidades</b>
<i>Valores de entrada</i>					
Área del campo solar	(ADS)	650.0	390.0	130.0	$m^2$
Volumen del tanque	(VOL)	12.0	6.0	1.0	$m^3$
Combustible de respaldo	(FL)	4	-	1	[-]
Locación climática	(CL)	4	-	1	[-]
<i>Valores de salida</i>					
Cantidad de $CO_2$ mitigada	(ACM)	107,051.30	74,982.80	12,128.60	kg $CO_2$
Costo total del ciclo de vida	(TLCC)	623,854.01	380,770.25	132,926.7	\$ USD
Valor presente neto	(NPV)	281,060.17	59,480.82	-535,405.36	\$ USD

Debido a que la función de transferencia empleada en las neuronas de la capa oculta es sigmoideal, es necesario llevar a cabo un proceso de tratamiento de datos, modificando los valores de entrada de tal forma que tengan valores entre 0.1 y 0.9 utilizando la ecuación (Jamshidi, y otros, 2016):

$$x_m = 0.8 \frac{X_m - x_{mín}}{x_{máx} - x_{mín}} - 0.1 \quad (3.1)$$

Donde  $x_m$  es el valor normalizado de  $X_m$  y  $x_{mín}$  y  $x_{máx}$  son los valores reportados en la Tabla 3.2. Los datos empleados para la creación de la ANN son divididos en 80% para el proceso de entrenamiento y el 20% restante para pruebas y validación. La función de transferencia empleada para la capa oculta es la tangente sigmoide y la función lineal para la capa de salida. La precisión en el modelo de inteligencia artificial obtenido mediante redes neuronales artificiales es medida a través del coeficiente de determinación  $R^2$ , el error cuadrático medio RMSE y el error porcentual absoluto medio MAPE:

$$R^2 = 1 - \frac{\sum_{i=1}^{\alpha} (y_{sim(i)} - y_{exp(i)})^2}{\sum_{i=1}^{\alpha} (y_{sim(i)} - \bar{y}_{exp})^2} \quad (3.2)$$

$$RMSE = \sqrt{\frac{1}{\alpha} \sum_{i=1}^{\alpha} (y_{sim(i)} - y_{exp(i)})^2} \quad (3.3)$$

$$MAPE = \frac{1}{\alpha} \sum_{i=1}^{\alpha} \left| \frac{y_{sim(i)} - y_{exp(i)}}{y_{exp(i)}} \right| \times 100 \quad (3.4)$$

Donde  $y_{sim(i)}$  es el valor estimado por la ANN,  $y_{exp(i)}$  es el valor obtenido a través de la experimentación numérica,  $\bar{y}_{exp}$  es el promedio de los valores deseados y  $\alpha$  es el número total de muestras por conjunto (May Tzuc, 2020).

### 3.3 Implementación de algoritmos de optimización

El estudio de optimización multiobjetivo considera a los valores de la capa de salida entregados por la ANN, NPV, ACM y TLCC, como las funciones objetivo a optimizar. Los tres algoritmos son empleados para optimizar  $\vec{y} = (y_1, y_2, y_3)$  considerando el siguiente criterio:

$$\begin{aligned} \min(y_1) &= -ACM(\vec{z}) \\ \min(y_2) &= -VPN(\vec{z}) \\ \min(y_3) &= TLCC(\vec{z}) \end{aligned} \quad (3.3)$$

Bajo la condición:

$$\vec{z}_m^{min} \leq \vec{z}_m \leq \vec{z}_m^{max} \quad (3.4)$$

Con  $m = 1, 2, 3$ . En la ecuación (3.3),  $y_1, y_2$  y  $y_3$  son las funciones objetivo; mientras que en la ecuación (3.4)  $\vec{z}_m$  es el vector con los parámetros de diseño normalizados ( $\vec{z}_m = (ADS, VOL)$ ) (May Tzuc, 2020). Las herramientas computacionales empleadas para el proceso de optimización multiobjetivo son el algoritmo genético, algoritmo de optimización de ballena y algoritmo de enjambre de partículas, discutidos en el capítulo previo.

En la Figura 3.4 se presenta un diagrama con las secciones metodológicas presentadas en este capítulo. En primera instancia, se desarrollan las ecuaciones gobernantes de los colectores solares de placa plana, así como aquellas que describen el proceso industrial de pasteurización láctea. La tecnología termosolar es integrada a la industria para satisfacer parte de la demanda térmica, generando una base de datos numérica obtenida al considerar las condiciones atmosféricas de cuatro regiones climáticas distintas. Posteriormente, se crea un modelo sustituto mediante redes neuronales artificiales, entrenado a partir de los resultados numéricos previamente obtenidos. Finalmente, este modelo es sometido a distintos algoritmos de optimización a fin de maximizar el valor presente neto y la reducción en las emisiones de gases contaminantes, así como minimizar el costo total del ciclo de vida.

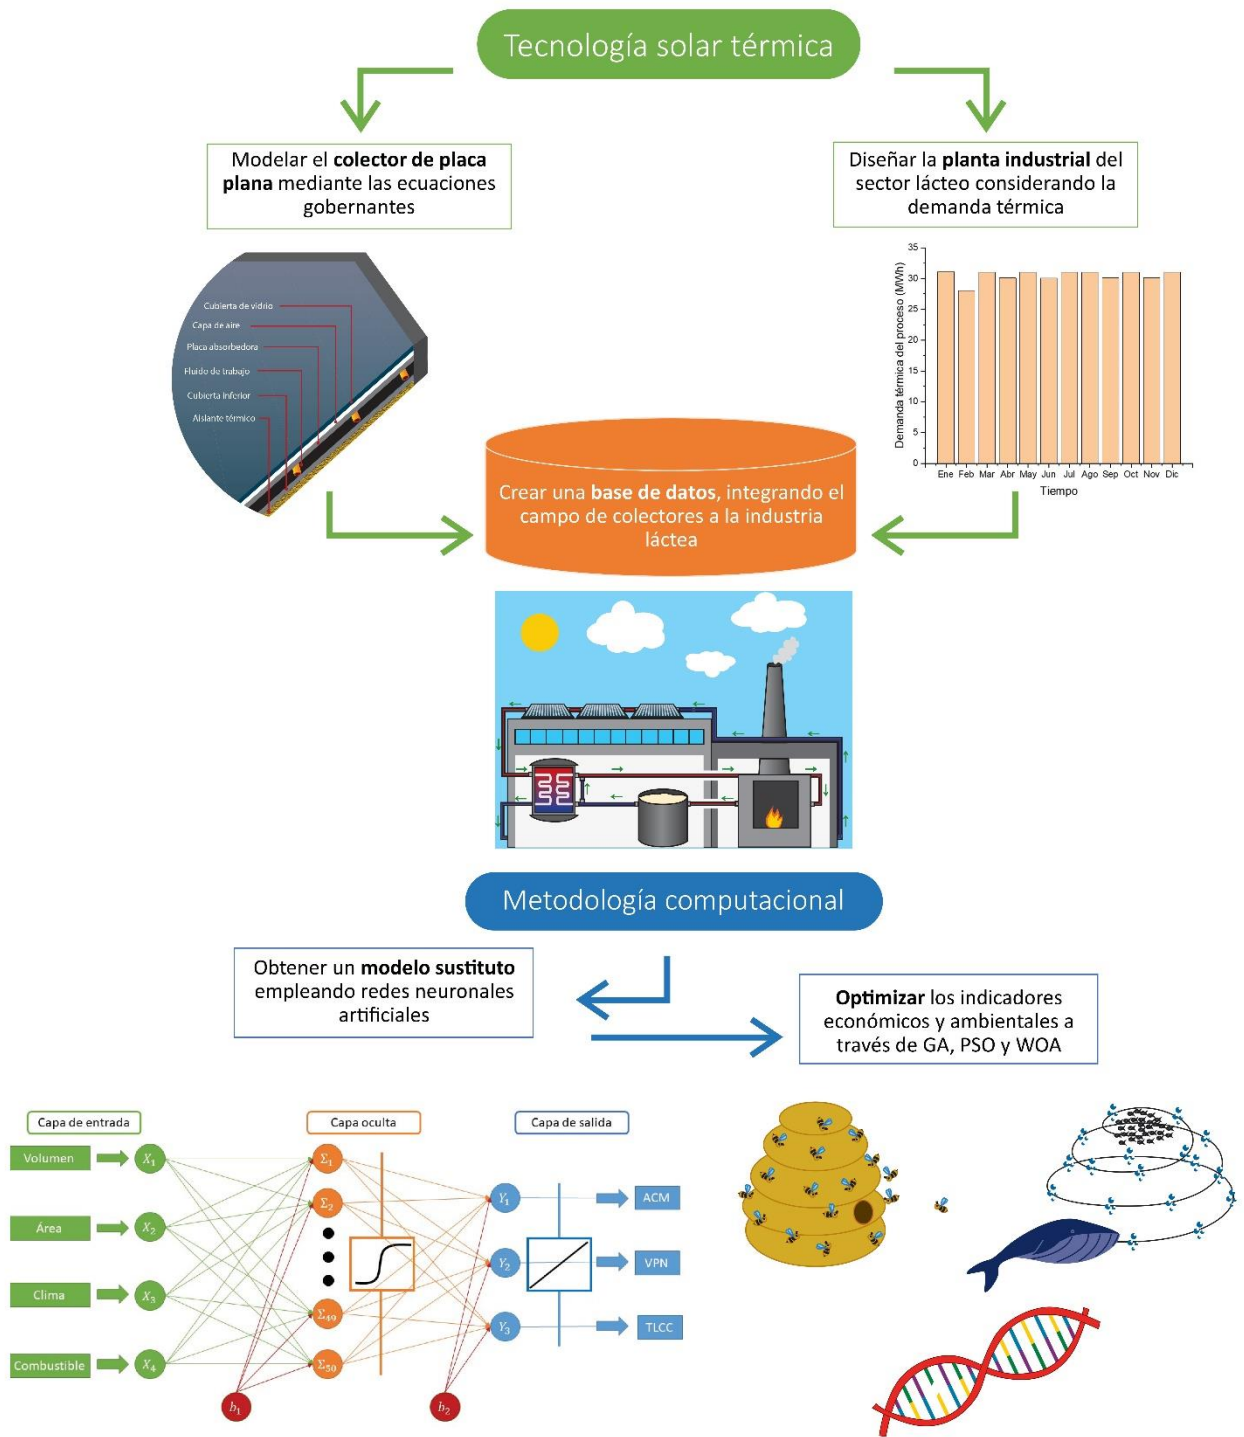


Figura 3.4 Estructura metodológica desarrollada en el presente trabajo.

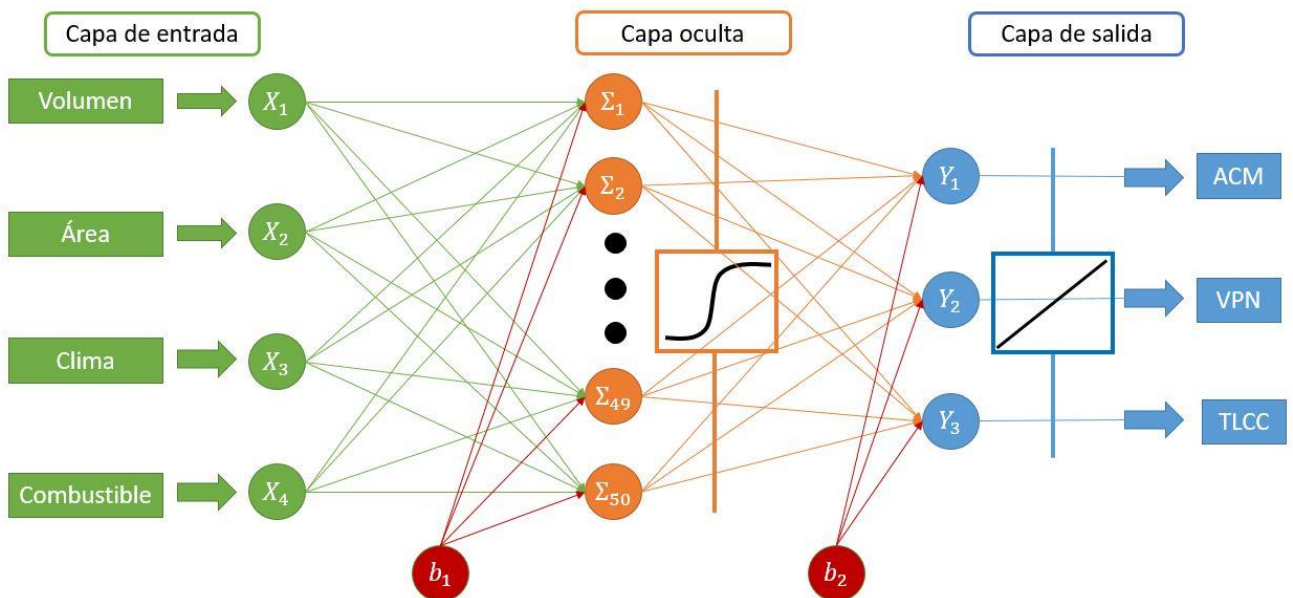


## Capítulo 4. Análisis de resultados

En este capítulo se lleva a cabo un análisis e interpretación de los indicadores económico y ambiental, así como los parámetros de diseño calculados mediante los distintos algoritmos de optimización propuestos.

### 4.1 Red neuronal artificial como modelo sustituto del sistema SHIP

Distintas arquitecturas para las redes neuronales fueron puestas a prueba empleando la base de datos obtenida del sistema SHIP, con el propósito de encontrar el modelo de inteligencia artificial que describa de la forma más confiable posible dicho sistema. A partir de prueba y error, la configuración de la red neuronal artificial con el mejor desempeño fue obtenida considerando los 4 parámetros de diseño en la capa de entrada, 50 neuronas en una única capa oculta y los 3 indicadores como neuronas en la capa de salida (Figura 4.1).

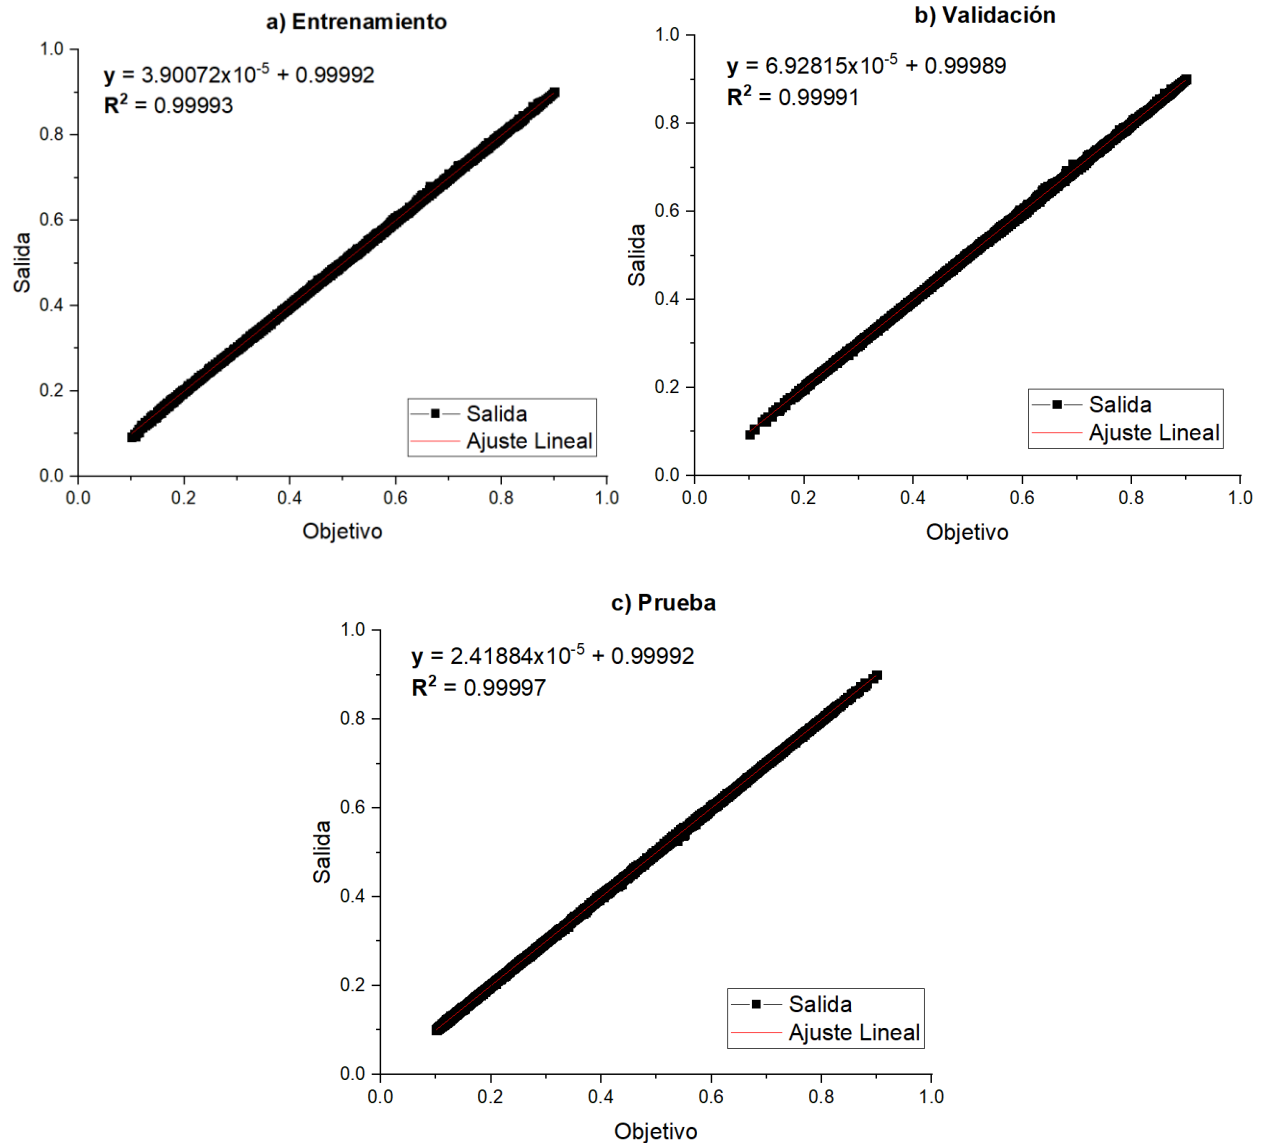


**Figura 4.1** Arquitectura de la ANN que representa todos los procedimientos realizados en el sistema SHIP.

Para determinar el grado de relación entre la ANN y los resultados del sistema SHIP obtenidos mediante experimentación numérica, se obtienen los parámetros estadísticos de la red en función del número de neuronas en la capa oculta (Tabla 4.1) así como las gráficas de regresión para las distintas etapas correspondientes al entrenamiento de la ANN (Figura 4.2). De la Tabla 4.1 se observa que, con una arquitectura de 50 neuronas en la capa oculta, todos los indicadores económico-ambientales cuentan con un coeficiente de determinación  $R^2$  mayor a 0.9999, así como un RMSE de  $8.2468 \times 10^{-4}$  y un MAPE menor a 0.2000. Mientras que en la Figura 4.2, para el entrenamiento, prueba y validación, así como en general para todos los datos, la relación de confiabilidad del modelo es mayor a  $R^2 = 0.9999$ . Estos resultados son un requisito indispensable para la ANN empleada en el presente trabajo, ya que se está creando el modelo sustituto para un proceso industrial de demanda de calor; debido a las estrictas metas de producción y criterios de cumplimiento que siguen las distintas empresas del sector lácteo, un error de cálculo puede llevar a consecuencias económicas no deseadas.

**Tabla 4.1** Parámetros estadísticos obtenidos al variar el número de neuronas en la capa oculta.

Neuronas ocultas	MAPE	RMSE	$R^2$		
			VPN	TLCC	ACM
30	0.4001	0.0017	0.99978	0.99995	0.99989
35	0.3014	0.0013	0.99986	0.99997	0.99991
40	0.2467	0.0011	0.99991	0.99998	0.99996
45	0.2019	$8.4742 \times 10^{-4}$	0.99993	0.99999	0.99997
50	0.1919	$8.2468 \times 10^{-4}$	0.99994	0.99999	0.99997



**Figura 4.2** Gráficas de regresión de la mejor arquitectura para la estimación del VPN, ACM y TLCC. Se presentan las etapas de entrenamiento (a), validación (b) y prueba (c) de la ANN.

## 4.2 Optimización multiobjetivo mediante GA, PSO y WOA

Una vez obtenido el modelo sustituto empleando ANN, se aplican los distintos algoritmos de optimización multiobjetivo para determinar los parámetros de diseño que maximizan ACM y NPV, al mismo tiempo que minimizan TLCC. En las Tablas 4.2 a 4.5 se presentan los parámetros de diseño, así como los indicadores económico y ambiental optimizados. Estos

algoritmos son aplicados para las 4 regiones climáticas, considerando los 4 escenarios de combustible empleados por el calentador auxiliar. Las zonas señaladas de color gris son aquellas que presentan valores económicamente viables, de acuerdo a las condiciones de operación planteadas por el proyecto.

Al analizar los resultados económicos para los distintos tipos de clima, se observa que el clima templado característico de Jalisco es aquel que presenta los mayores valores presentes netos, al mismo tiempo que logra minimizar el costo total del ciclo de vida asociado al proyecto. Estas características económicas posicionan a Jalisco como el lugar ideal para llevar a cabo este proyecto industrial de calor solar. Por otra parte, Coahuila con su clima árido presenta los valores más bajos de NPV, mientras que tanto Mérida (clima tropical) como Monterrey (clima seco) presentan TLCC por arriba de los  $\$ 4 \times 10^5 USD$ .

Los diversos tipos de combustibles empleados para el calentador auxiliar permiten establecer cuáles son los panoramas de viabilidad económica y ambiental para cada región climática. El diésel destaca como aquel capaz de entregar escenarios donde los tres indicadores presentan resultados favorables, para todas las condiciones climáticas estudiadas. Considerando los casos de Coahuila y Jalisco, el gas LP también puede ser tomado en cuenta para activar el calentador auxiliar. Es importante mencionar que el combustóleo y el gas natural son dos combustibles que no ofrecen viabilidad económico-ambiental al proceso industrial lácteo en México, considerando la tecnología solar empleada y las cuatro principales regiones climáticas estudiadas.

En relación a los algoritmos de optimización empleados, el enjambre de partículas (PSO) es el que converge con mayor rapidez; por otra parte, el algoritmo de optimización de ballenas presenta los tiempos de cómputo más alto, entregando a cambio desviaciones estándar más pequeñas para la mayoría de los casos. El algoritmo genético es una alternativa intermedia para la obtención de los parámetros optimizados. Una comparación entre la precisión de los resultados entregados por cada algoritmo es presentada a continuación, empleando los diagramas de Pareto.

**Tabla 4.2** Parámetros de diseño del sistema SHIP obtenidos mediante los distintos algoritmos de optimización para el caso de Coahuila, considerando los 4 escenarios de combustible para el calentador auxiliar.

Combustible para el calentador auxiliar	Algoritmos de optimización	Tiempo de cómputo [s]		Volumen del tanque [ $m^3$ ]		Área del campo solar [ $m^2$ ]		ACM [ $kg CO_2$ ]		VPN [\$ USD]		TLCC [\$ USD]	
		Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar
Diésel	GA	90.57	12.22	12.00	$3.47 \times 10^{-4}$	637.29	8.15	$8.07 \times 10^7$	$4.40 \times 10^5$	$1.21 \times 10^5$	$2.05 \times 10^3$	$3.86 \times 10^5$	$1.69 \times 10^2$
	PSO	84.03	3.80	11.96	$3.19 \times 10^{-3}$	639.53	6.75	$8.08 \times 10^7$	$3.66 \times 10^5$	$1.22 \times 10^5$	$1.67 \times 10^3$	$3.86 \times 10^5$	$1.53 \times 10^2$
	WOA	220.52	20.35	12.00	$3.04 \times 10^{-4}$	627.88	14.48	$8.11 \times 10^7$	$5.15 \times 10^5$	$1.23 \times 10^5$	$2.28 \times 10^3$	$3.86 \times 10^5$	$2.34 \times 10^2$
Combustóleo	GA	101.55	1.64	4.95	4.46	517.89	77.45	$7.82 \times 10^7$	$6.46 \times 10^6$	$-7.03 \times 10^4$	$6.13 \times 10^3$	$2.56 \times 10^5$	$1.16 \times 10^4$
	PSO	86.76	0.86	5.55	4.73	532.56	78.91	$7.93 \times 10^7$	$6.54 \times 10^6$	$-6.97 \times 10^4$	$6.22 \times 10^3$	$2.58 \times 10^5$	$1.20 \times 10^4$
	WOA	214.75	15.35	5.95	4.74	546.62	71.01	$8.05 \times 10^7$	$5.78 \times 10^6$	$-6.82 \times 10^4$	$5.35 \times 10^3$	$2.59 \times 10^5$	$1.14 \times 10^4$
Gas natural	GA	114.78	8.77	3.23	3.66	376.23	156.45	$4.66 \times 10^7$	$1.89 \times 10^7$	$-1.17 \times 10^5$	$1.16 \times 10^4$	$1.77 \times 10^5$	$2.70 \times 10^4$
	PSO	88.00	1.32	4.19	4.35	415.26	162.75	$5.10 \times 10^7$	$1.94 \times 10^7$	$-1.19 \times 10^5$	$1.24 \times 10^4$	$1.84 \times 10^5$	$2.88 \times 10^4$
	WOA	208.42	9.93	4.11	4.30	424.21	158.12	$5.21 \times 10^7$	$1.85 \times 10^7$	$-1.19 \times 10^5$	$1.23 \times 10^4$	$1.85 \times 10^5$	$2.83 \times 10^4$
Gas LP	GA	92.12	1.59	8.21	4.53	571.94	24.49	$5.87 \times 10^7$	$1.72 \times 10^6$	$1.92 \times 10^4$	$8.73 \times 10^3$	$3.31 \times 10^5$	$1.31 \times 10^3$
	PSO	84.99	2.31	9.92	3.79	584.85	29.22	$5.95 \times 10^7$	$1.72 \times 10^6$	$2.36 \times 10^4$	$8.99 \times 10^3$	$3.31 \times 10^5$	$1.31 \times 10^3$
	WOA	213.67	10.94	10.50	3.40	583.55	21.92	$5.96 \times 10^7$	$1.38 \times 10^6$	$2.38 \times 10^4$	$6.99 \times 10^3$	$3.32 \times 10^5$	$1.13 \times 10^3$

**Tabla 4.3** Parámetros de diseño del sistema SHIP obtenidos mediante los distintos algoritmos de optimización para el caso de Jalisco, considerando los 4 escenarios de combustible para el calentador auxiliar.

Combustible para el calentador auxiliar	Algoritmos de optimización	Tiempo de cómputo [s]		Volumen del tanque [ $m^3$ ]		Área del campo solar [ $m^2$ ]		ACM [ $kg CO_2$ ]		VPN [\$ USD]		TLCC [\$ USD]	
		Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar
Diésel	GA	86.39	1.76	12.00	$6.50 \times 10^{-4}$	625.65	14.58	$8.59 \times 10^7$	$6.76 \times 10^5$	$1.95 \times 10^5$	$3.41 \times 10^3$	$3.47 \times 10^5$	$4.22 \times 10^2$
	PSO	81.39	1.76	11.89	$3.29 \times 10^{-3}$	630.32	14.14	$8.61 \times 10^7$	$6.62 \times 10^5$	$1.95 \times 10^5$	$3.30 \times 10^3$	$3.47 \times 10^5$	$4.50 \times 10^2$
	WOA	221.17	9.93	12.00	$5.26 \times 10^{-4}$	628.81	15.42	$8.61 \times 10^7$	$7.20 \times 10^5$	$1.95 \times 10^5$	$3.64 \times 10^3$	$3.47 \times 10^5$	$4.70 \times 10^2$
Combustóleo	GA	102.78	13.25	6.82	5.06	494.99	83.02	$8.43 \times 10^7$	$6.85 \times 10^6$	$-3.65 \times 10^4$	$5.03 \times 10^3$	$2.36 \times 10^5$	$1.27 \times 10^4$
	PSO	87.92	1.58	6.56	5.08	492.33	82.17	$8.40 \times 10^7$	$6.80 \times 10^6$	$-3.67 \times 10^4$	$5.07 \times 10^3$	$2.36 \times 10^5$	$1.25 \times 10^4$
	WOA	218.41	20.47	8.00	4.89	514.08	75.90	$8.60 \times 10^7$	$6.04 \times 10^6$	$-3.51 \times 10^4$	$3.82 \times 10^3$	$2.39 \times 10^5$	$1.20 \times 10^4$
Gas natural	GA	105.43	1.54	4.04	4.53	360.83	150.19	$5.19 \times 10^7$	$1.87 \times 10^7$	$-9.89 \times 10^4$	$1.43 \times 10^4$	$1.66 \times 10^5$	$2.76 \times 10^4$
	PSO	93.06	5.11	4.74	4.87	404.97	153.14	$5.70 \times 10^7$	$1.83 \times 10^7$	$-1.01 \times 10^5$	$1.41 \times 10^4$	$1.74 \times 10^5$	$2.87 \times 10^4$
	WOA	200.07	4.51	5.05	4.95	416.41	150.01	$5.85 \times 10^7$	$1.78 \times 10^7$	$-1.01 \times 10^5$	$1.46 \times 10^4$	$1.76 \times 10^5$	$2.87 \times 10^4$
Gas LP	GA	96.05	2.63	9.85	3.97	568.16	56.26	$6.35 \times 10^7$	$3.02 \times 10^6$	$7.88 \times 10^4$	$1.60 \times 10^4$	$3.01 \times 10^5$	$2.55 \times 10^3$
	PSO	84.43	1.73	11.24	2.30	584.52	45.31	$6.45 \times 10^7$	$2.17 \times 10^6$	$8.41 \times 10^4$	$1.11 \times 10^4$	$3.02 \times 10^5$	$2.35 \times 10^3$
	WOA	202.03	1.08	11.40	2.38	587.42	42.72	$6.47 \times 10^7$	$2.07 \times 10^6$	$8.50 \times 10^4$	$1.06 \times 10^4$	$3.02 \times 10^5$	$2.26 \times 10^3$

**Tabla 4.4** Parámetros de diseño del sistema SHIP obtenidos mediante los distintos algoritmos de optimización para el caso de Mérida, considerando los 4 escenarios de combustible para el calentador auxiliar.

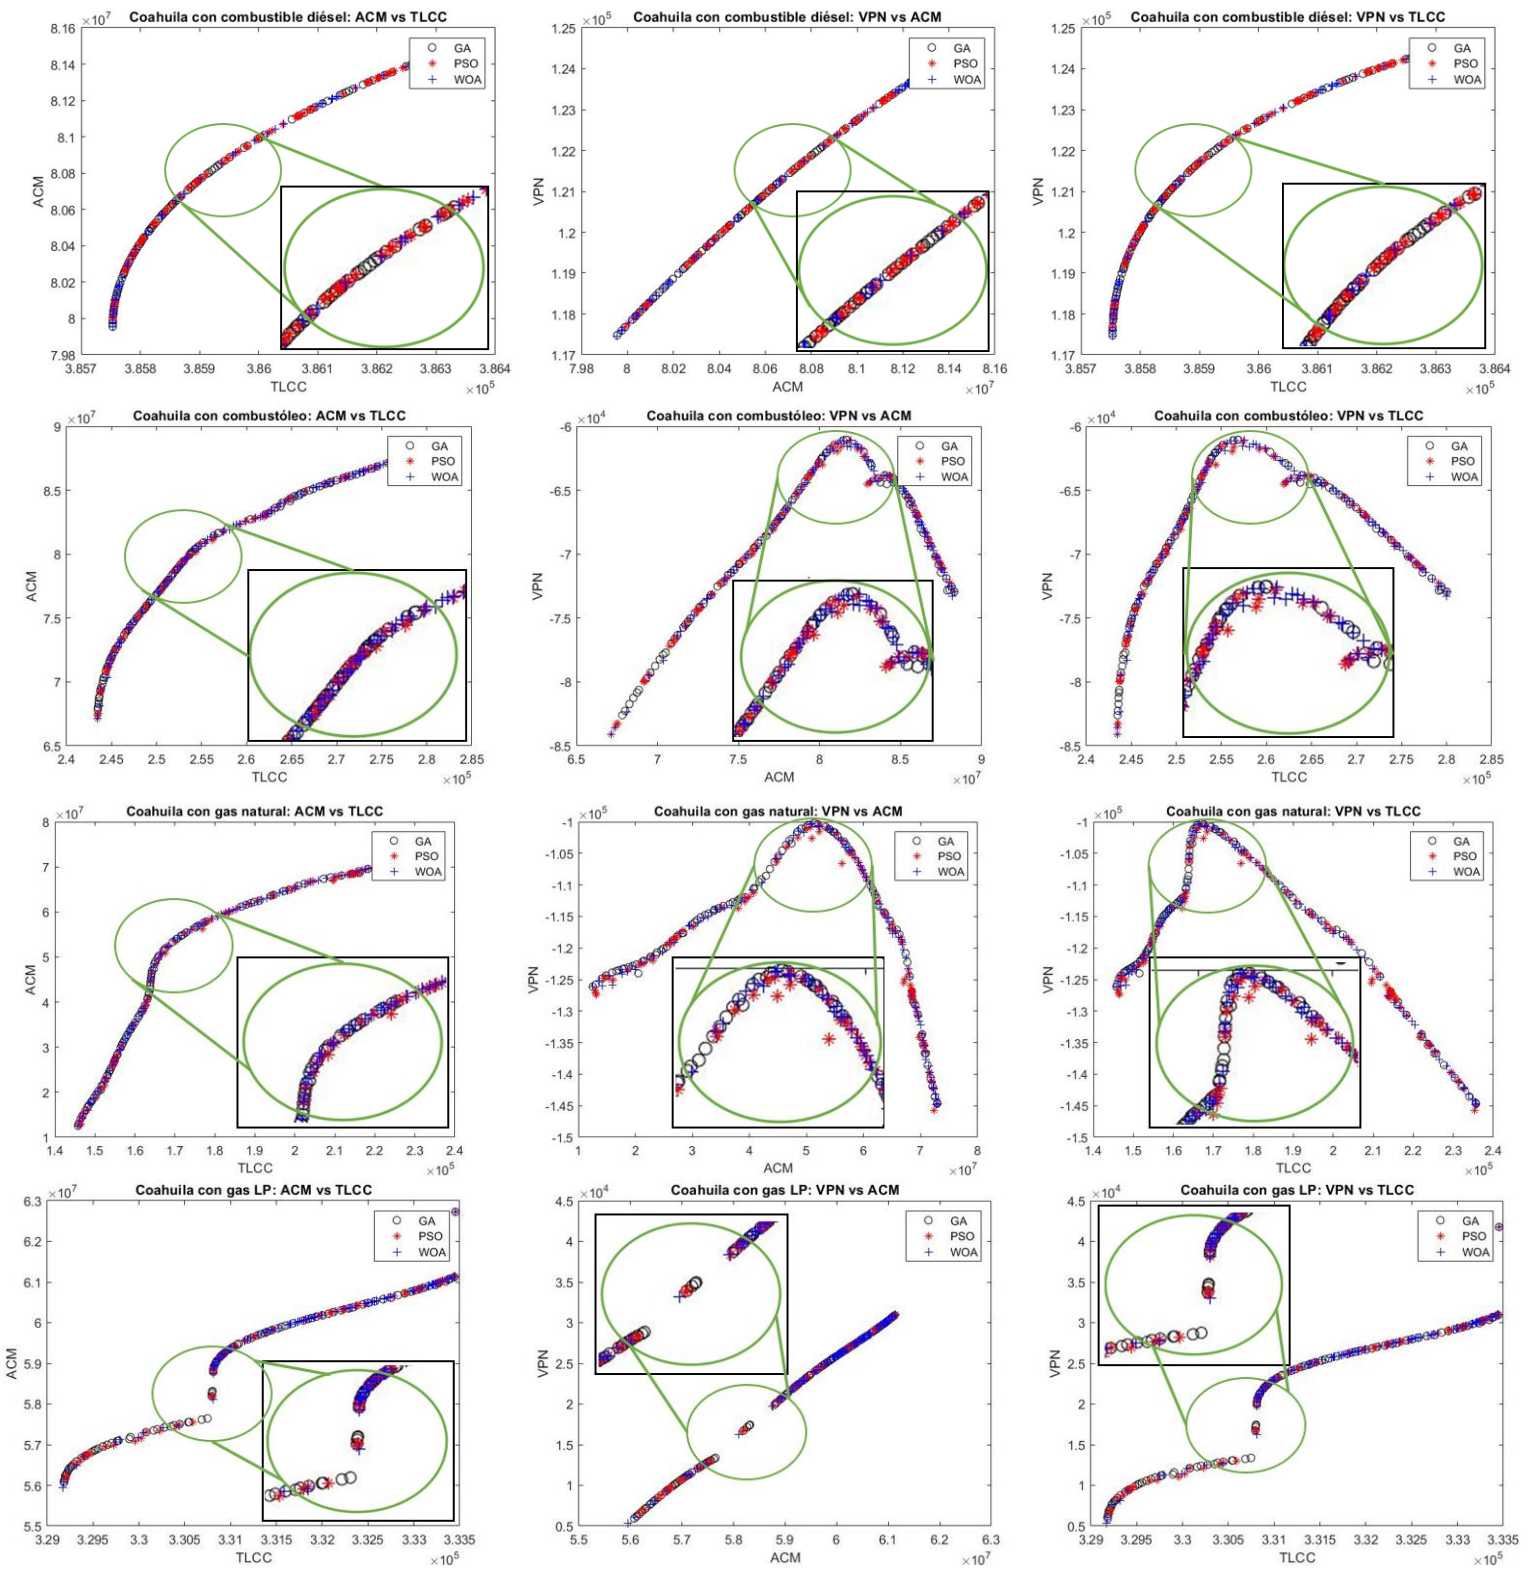
Combustible para el calentador auxiliar	Algoritmos de optimización	Tiempo de cómputo [s]		Volumen del tanque [ $m^3$ ]		Área del campo solar [ $m^2$ ]		ACM [ $kg CO_2$ ]		VPN [\$ USD]		TLCC [\$ USD]	
		Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar
Diésel	GA	76.15	5.20	11.99	$6.023 \times 10^{-7}$	651.86	$4.40 \times 10^{-5}$	$7.39 \times 10^7$	2.70	$3.09 \times 10^4$	$1.12 \times 10^{-2}$	$4.33 \times 10^5$	$6.42 \times 10^{-4}$
	PSO	81.31	1.71	11.79	$4.11 \times 10^{-15}$	647.03	$6.29 \times 10^{-13}$	$7.35 \times 10^7$	$9.74 \times 10^{-8}$	$2.86 \times 10^4$	$7.60 \times 10^{-11}$	$4.33 \times 10^5$	$3.02 \times 10^{-10}$
	WOA	204.94	4.78	12	0	651.99	$6.85 \times 10^{-13}$	$7.39 \times 10^7$	$1.20 \times 10^{-7}$	$3.10 \times 10^4$	$5.65 \times 10^{-11}$	$4.33 \times 10^5$	$3.10 \times 10^{-10}$
Combustóleo	GA	93.35	2.23	4.31	3.66	528.16	73.34	$7.00 \times 10^7$	$6.30 \times 10^6$	$-1.11 \times 10^5$	$6.13 \times 10^3$	$2.77 \times 10^5$	$9.99 \times 10^3$
	PSO	84.70	1.65	4.55	3.84	536.73	74.45	$7.06 \times 10^7$	$6.40 \times 10^6$	$-1.10 \times 10^5$	$6.19 \times 10^3$	$2.78 \times 10^5$	$1.01 \times 10^4$
	WOA	199.71	4.45	5.11	3.96	555.26	64.60	$7.23 \times 10^7$	$5.43 \times 10^6$	$-1.08 \times 10^5$	$4.51 \times 10^3$	$2.80 \times 10^5$	$9.52 \times 10^3$
Gas natural	GA	101.76	1.85	2.94	3.08	384.22	156.52	$4.10 \times 10^7$	$1.74 \times 10^7$	$-1.32 \times 10^5$	$1.08 \times 10^4$	$1.85 \times 10^5$	$2.80 \times 10^4$
	PSO	87.03	0.96	2.80	2.64	419.41	159.46	$4.47 \times 10^7$	$1.74 \times 10^7$	$-1.34 \times 10^5$	$1.13 \times 10^4$	$1.91 \times 10^5$	$2.83 \times 10^4$
	WOA	203.15	5.64	3.00	2.90	423.11	155.29	$4.52 \times 10^7$	$1.70 \times 10^7$	$-1.33 \times 10^5$	$1.10 \times 10^4$	$1.92 \times 10^5$	$2.79 \times 10^4$
Gas LP	GA	94.36	1.48	3.44	1.46	585.68	18.37	$5.24 \times 10^7$	$1.04 \times 10^6$	$-5.34 \times 10^4$	$5.43 \times 10^3$	$3.66 \times 10^5$	718.89
	PSO	82.31	1.58	3.89	2.41	592.20	22.03	$5.28 \times 10^7$	$1.44 \times 10^6$	$-5.14 \times 10^4$	$7.75 \times 10^3$	$3.66 \times 10^5$	723.38
	WOA	201.94	4.58	10.93	2.90	643.54	23.45	$5.66 \times 10^7$	$1.68 \times 10^6$	$-3.02 \times 10^4$	$9.17 \times 10^3$	$3.67 \times 10^5$	528.52

**Tabla 4.5** Parámetros de diseño del sistema SHIP obtenidos mediante los distintos algoritmos de optimización para el caso de Monterrey, considerando los 4 escenarios de combustible para el calentador auxiliar.

Combustible para el calentador auxiliar	Algoritmos de optimización	Tiempo de cómputo [s]		Volumen del tanque [ $m^3$ ]		Área del campo solar [ $m^2$ ]		ACM [ $kg CO_2$ ]		VPN [\$ USD]		TLCC [\$ USD]	
		Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar	Promedio	Desviación estándar
Diésel	GA	85.23	1.64	12.00	$4.12 \times 10^{-4}$	640.82	6.17	$7.30 \times 10^7$	$2.90 \times 10^5$	$2.37 \times 10^4$	$1.55 \times 10^3$	$4.35 \times 10^5$	139.13
	PSO	79.87	1.94	11.79	$3.94 \times 10^{-4}$	641.37	4.69	$7.30 \times 10^7$	$2.20 \times 10^5$	$2.34 \times 10^4$	$1.16 \times 10^3$	$4.35 \times 10^5$	115.04
	WOA	204.98	1.63	12.00	$2.72 \times 10^{-4}$	647.52	6.82	$7.33 \times 10^7$	$3.21 \times 10^5$	$2.53 \times 10^4$	$1.67 \times 10^3$	$4.36 \times 10^5$	178.76
Combustóleo	GA	99.76	1.47	4.02	3.59	511.81	80.73	$6.93 \times 10^7$	$6.41 \times 10^6$	$-1.10 \times 10^5$	$4.65 \times 10^3$	$2.74 \times 10^5$	$1.17 \times 10^4$
	PSO	85.97	2.31	3.88	3.55	512.81	82.89	$6.92 \times 10^7$	$6.50 \times 10^6$	$-1.10 \times 10^5$	$4.61 \times 10^3$	$2.74 \times 10^5$	$1.20 \times 10^4$
	WOA	198.03	1.59	4.76	4.04	536.70	73.91	$7.13 \times 10^7$	$5.75 \times 10^6$	$-1.08 \times 10^5$	$3.46 \times 10^3$	$2.77 \times 10^5$	$1.15 \times 10^4$
Gas natural	GA	102.25	0.95	3.12	2.97	384.59	157.57	$4.25 \times 10^7$	$1.66 \times 10^7$	$-1.32 \times 10^5$	$1.24 \times 10^4$	$1.86 \times 10^5$	$2.76 \times 10^4$
	PSO	88.33	1.53	2.84	1.98	421.67	158.05	$4.62 \times 10^7$	$1.63 \times 10^7$	$-1.33 \times 10^5$	$1.27 \times 10^4$	$1.92 \times 10^5$	$2.74 \times 10^4$
	WOA	198.44	2.05	3.56	3.35	430.35	156.91	$4.71 \times 10^7$	$1.61 \times 10^7$	$-1.34 \times 10^5$	$1.31 \times 10^4$	$1.94 \times 10^5$	$2.82 \times 10^4$
Gas LP	GA	92.04	1.94	8.06	4.44	582.77	35.65	$5.30 \times 10^7$	$2.09 \times 10^6$	$-5.07 \times 10^4$	$1.11 \times 10^4$	$3.68 \times 10^5$	$1.80 \times 10^3$
	PSO	85.74	0.98	9.61	3.91	593.98	34.65	$5.38 \times 10^7$	$1.95 \times 10^6$	$-4.68 \times 10^4$	$1.02 \times 10^4$	$3.68 \times 10^5$	$1.74 \times 10^3$
	WOA	209.70	2.17	10.31	3.49	599.08	31.59	$5.41 \times 10^7$	$1.73 \times 10^6$	$-4.51 \times 10^4$	$9.03 \times 10^3$	$3.68 \times 10^5$	$1.59 \times 10^3$

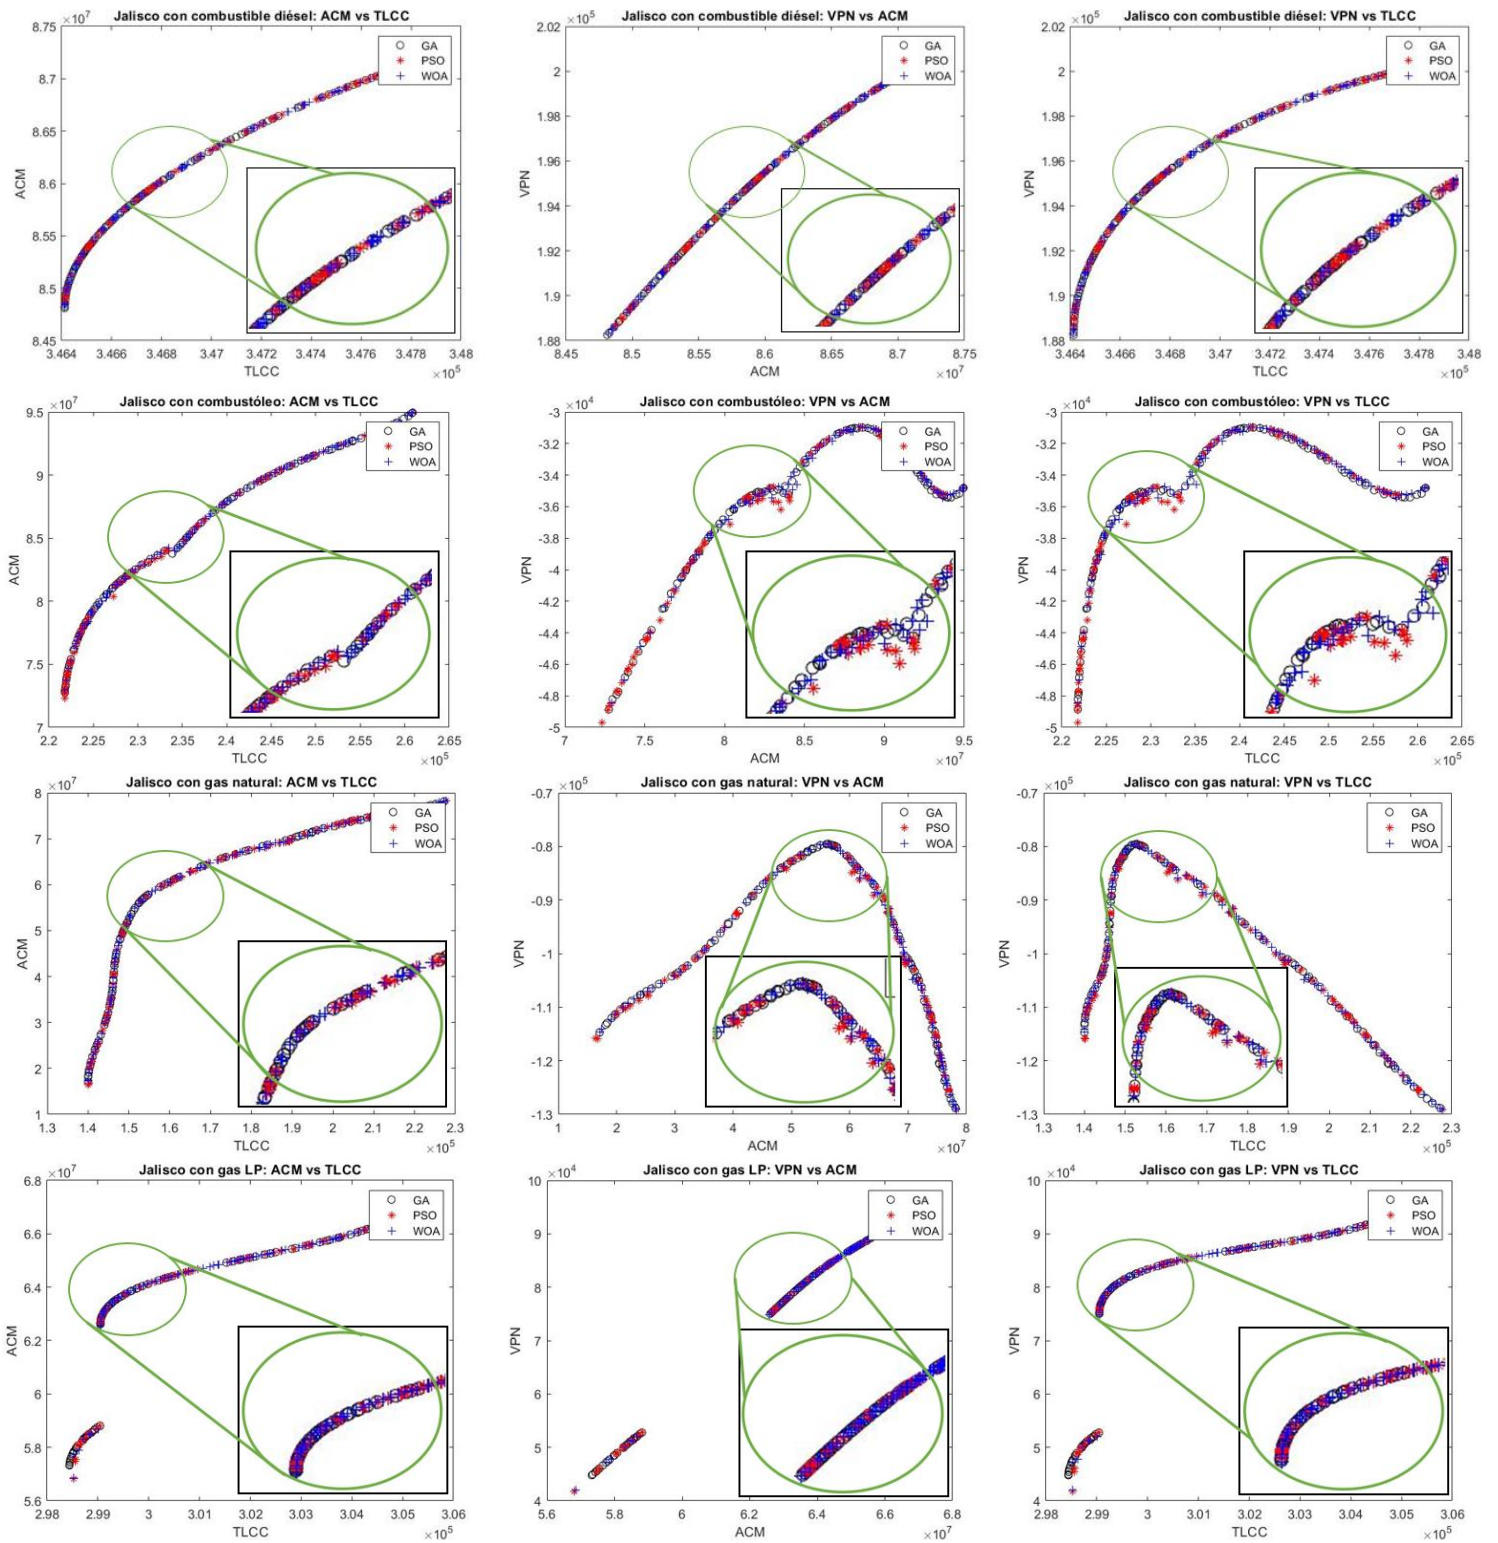
En las Figuras 4.3 a 4.6 se muestran los diagramas de Pareto obtenidos para todas las combinaciones posibles entre condiciones climáticas y escenarios de combustible para el calentador auxiliar, empleando los distintos algoritmos de optimización. Al obtener estas regiones de soluciones óptimas, se presentan casos particulares como el de Mérida con diésel como combustible para el calentador auxiliar (Figura 4.5); para esta configuración, los algoritmos son capaces de encontrar soluciones óptimas, sin embargo, éstas no satisfacen los criterios económico-ambientales planteados por el proyecto. También se presentan regiones de discontinuidad al utilizar el gas LP en Coahuila, Jalisco y Monterrey. Por otra parte, al emplear el gas natural como combustible, se observa una región de soluciones bien definida para las cuatro locaciones climáticas.

Cada uno de los diagramas de Pareto cuenta con un acercamiento en las zonas de mayor convergencia entre los tres algoritmos empleados. Es importante destacar el comportamiento de las soluciones presentadas por cada algoritmo en comparación con el tiempo de cómputo reportado en las Tablas 4.2 a 4.5. De las Figuras 4.3 a 4.6 y considerando todos los tipos de combustible, se observa que WOA es aquel que presenta la región de soluciones más continua y con el menor número de puntos fuera del diagrama de Pareto claramente establecido. Sin embargo, este mismo algoritmo es el que requiere de una mayor cantidad de tiempo de cómputo para generar dicho diagrama. De esta manera, se observa que el tiempo invertido se ve recompensado con una mayor precisión en la región de resultados óptimos reflejados a través del diagrama de Pareto. Los algoritmos GA y PSO son capaces de entregar soluciones en un menor tiempo; sin embargo, ambos presentan soluciones que salen del diagrama creado por cada uno.

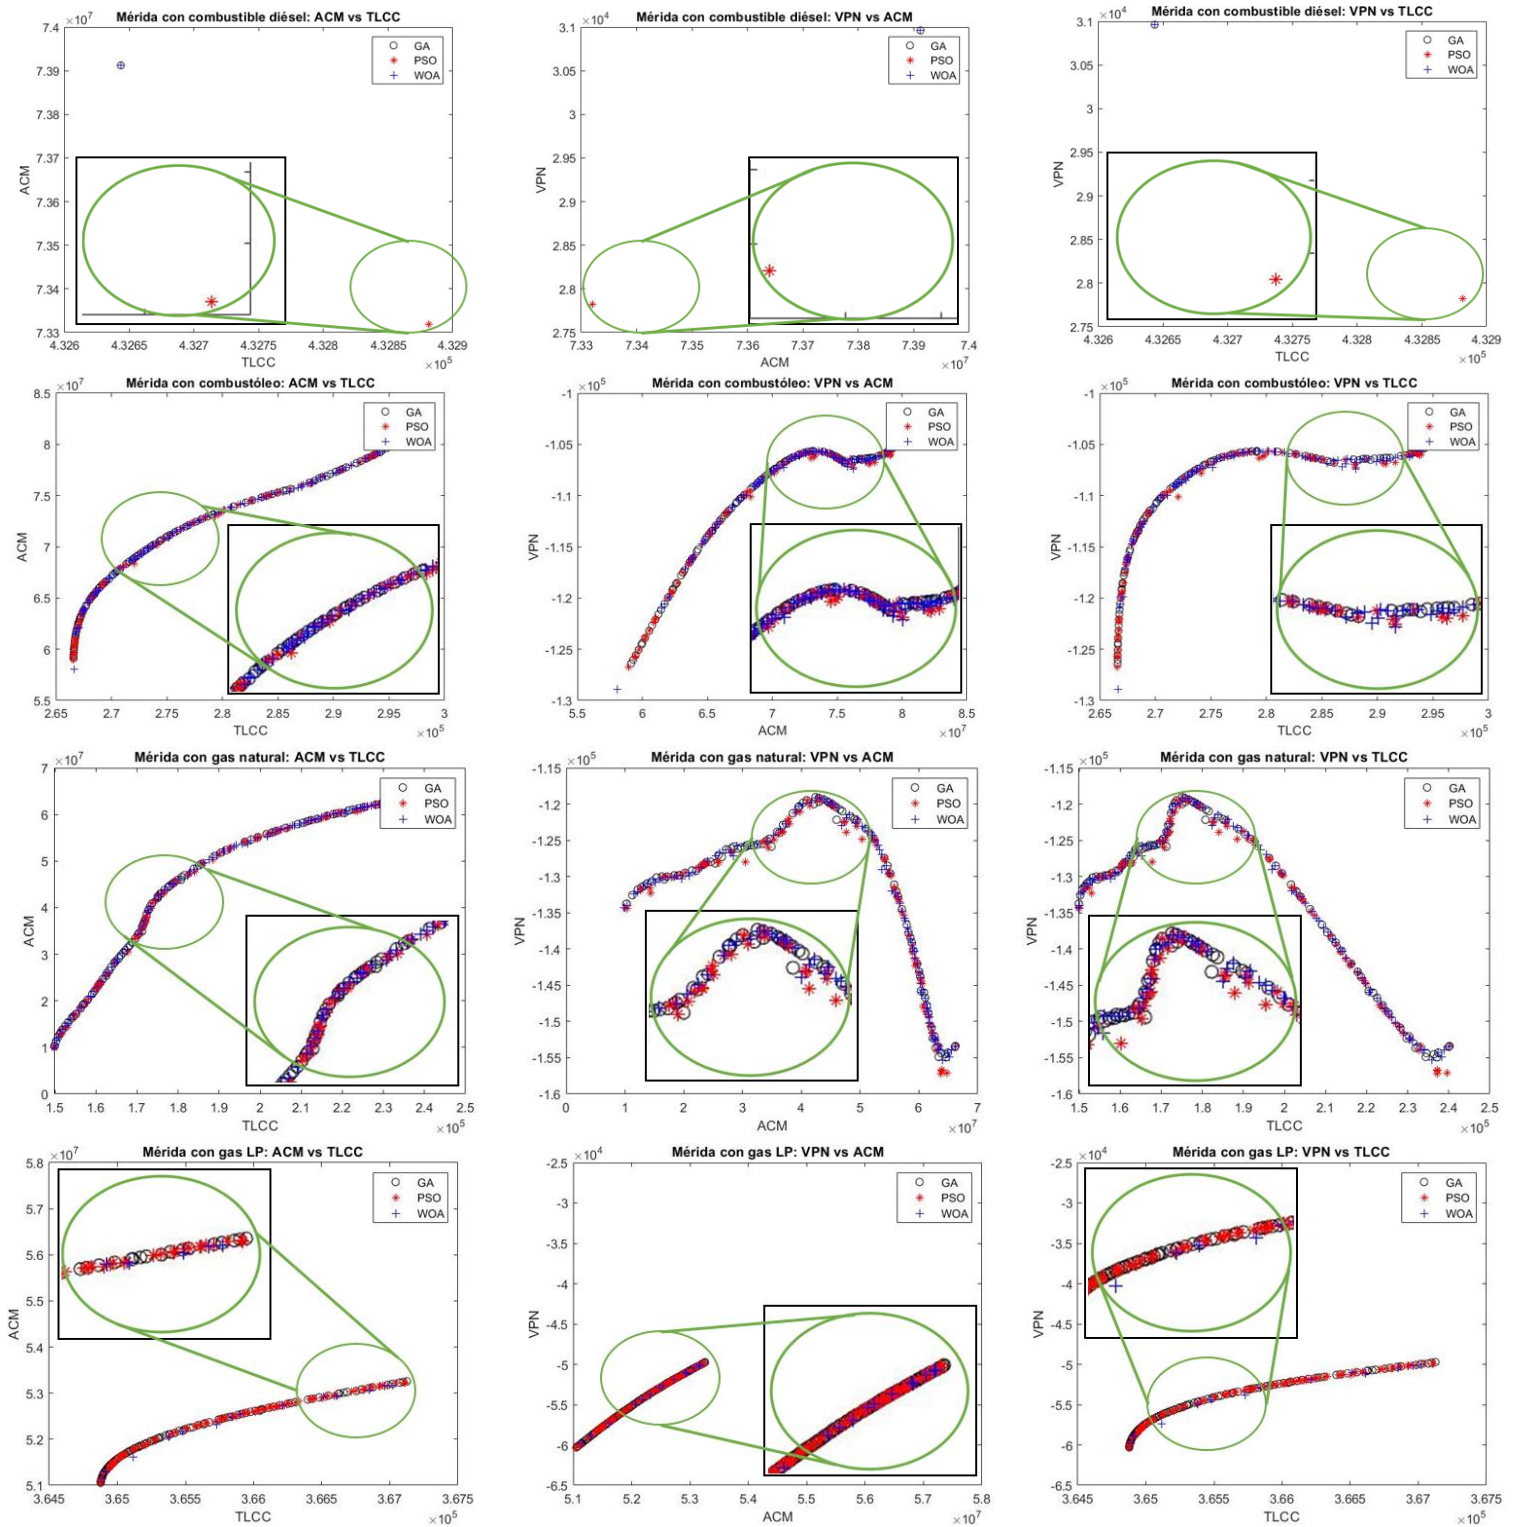


**Figura 4.3** Diagramas de Pareto obtenidos mediante los distintos algoritmos de optimización, considerando los 4 combustibles del calentador auxiliar para el clima de Coahuila

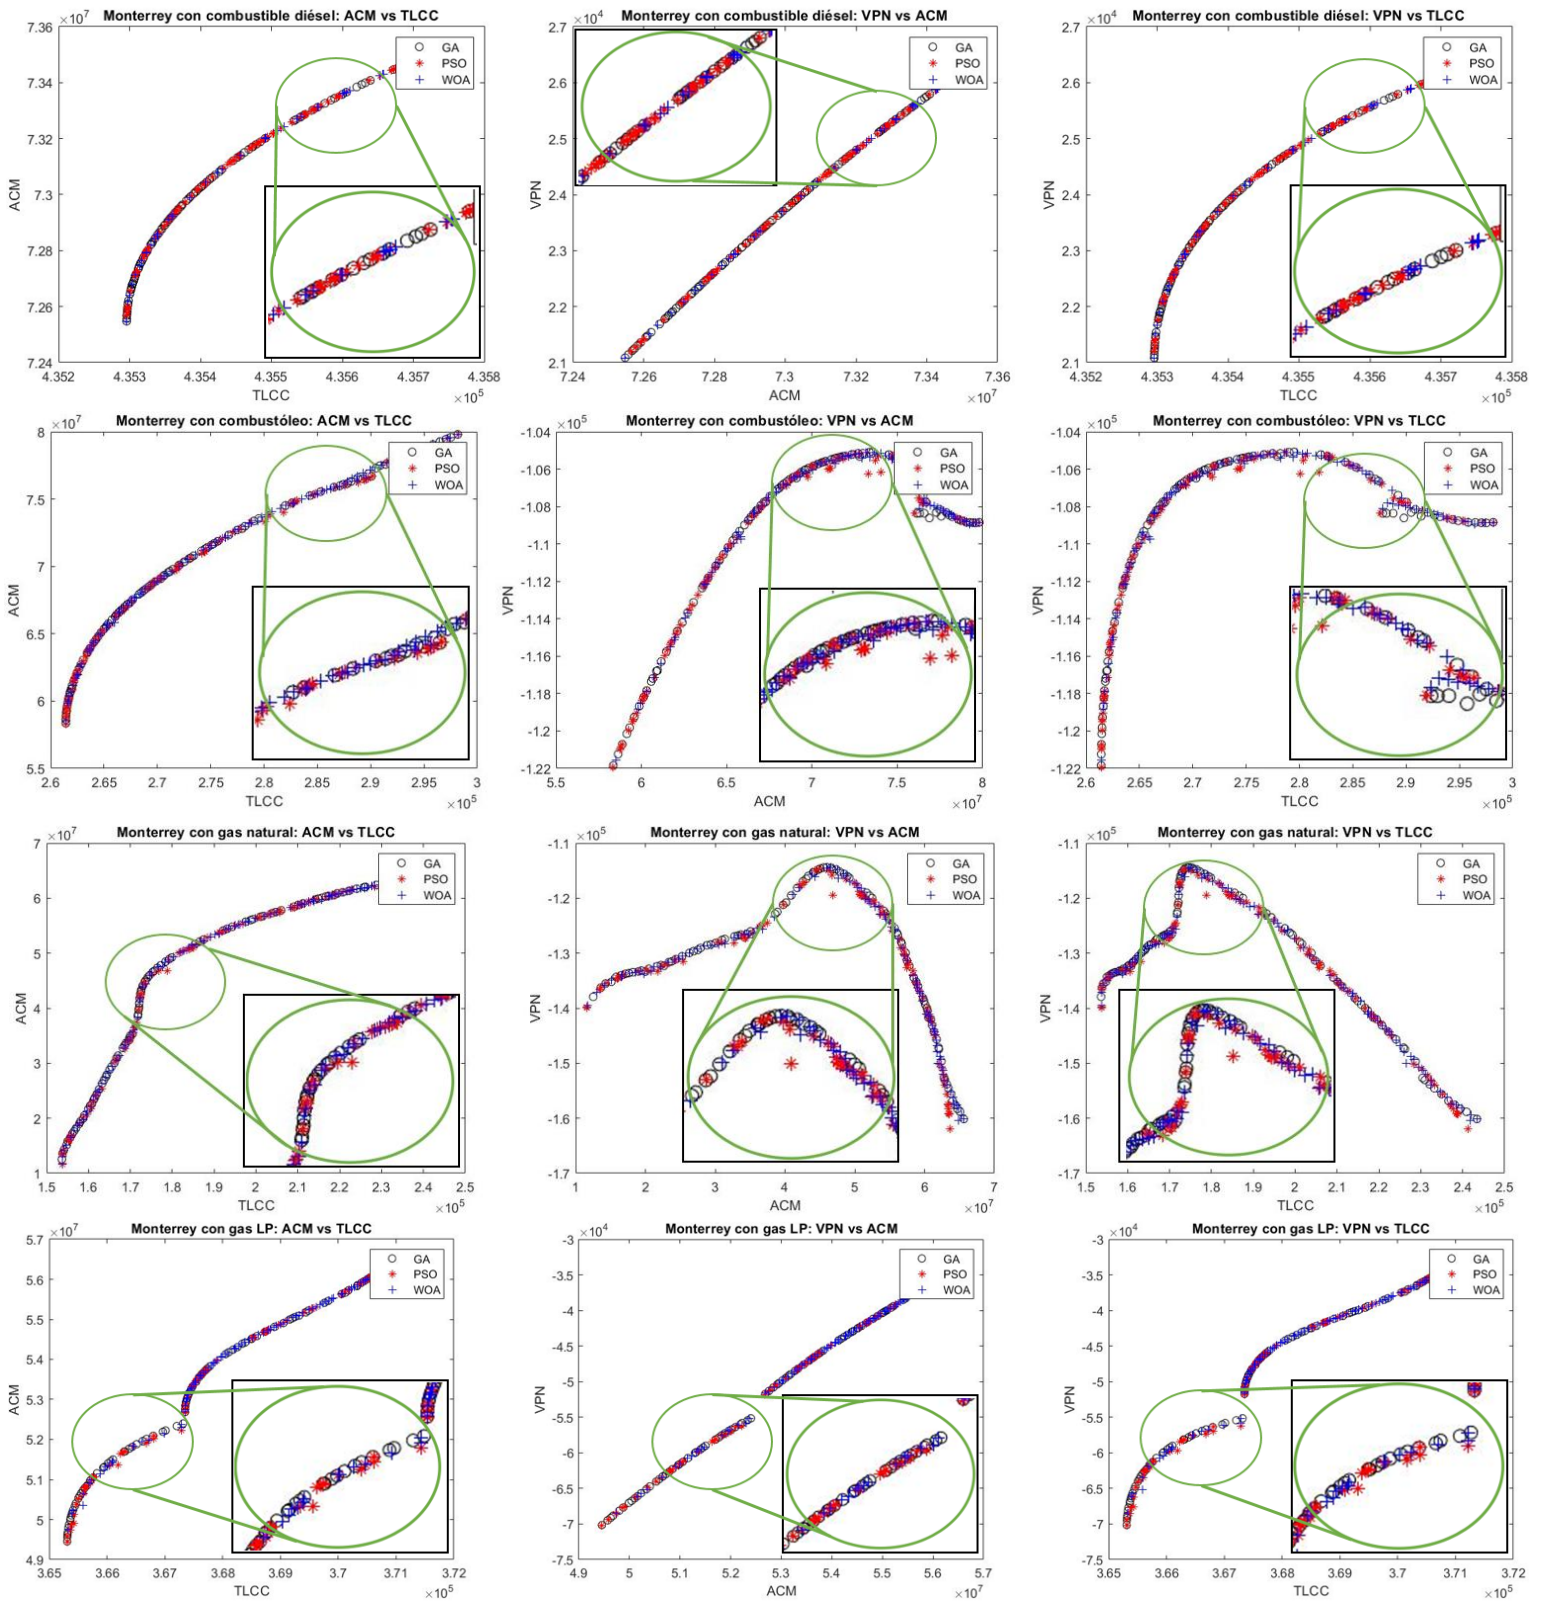




**Figura 4.4** Diagramas de Pareto obtenidos mediante los distintos algoritmos de optimización, considerando los 4 combustibles del calentador auxiliar para el clima de Jalisco



**Figura 4.5** Diagramas de Pareto obtenidos mediante los distintos algoritmos de optimización, considerando los 4 combustibles del calentador auxiliar para el clima de Mérida



**Figura 4.6** Diagramas de Pareto obtenidos mediante los distintos algoritmos de optimización, considerando los 4 combustibles del calentador auxiliar para el clima de Monterrey

## Conclusiones

En el presente trabajo de investigación se implementó una metodología computacional basada en técnicas de inteligencia artificial, a fin de modelar y optimizar los parámetros económico-ambientales resultantes de la implementación de colectores solares de placa plana para satisfacer la demanda térmica asociada al proceso de pasteurización en la industria láctea. A partir de las ecuaciones que rigen el comportamiento térmico y energético de los colectores solares de placa plana y conociendo las características de operación del proceso industrial, se obtuvieron los valores de los indicadores VPN, TLCC y ACM para este sistema SHIP. Un calentador auxiliar conectado en serie suministró calor al proceso cuando el entregado por el campo de colectores solares no era suficiente; los combustibles considerados para el funcionamiento del calentador fueron diésel, combustóleo, gas natural y gas LP. Además, los resultados relacionados al calor solar entregado por los colectores de placa plana fueron obtenidos considerando datos climáticos de cuatro regiones del país, las cuales presentan clima árido (Coahuila), templado (Jalisco), tropical (Mérida) y seco (Monterrey). Tomando como parámetros de diseño al área ocupada por el campo de colectores solares, el volumen del tanque de almacenamiento térmico, la región climática y el combustible del calentador auxiliar, se creó una base de datos con 22,464 resultados obtenidos a partir de la experimentación numérica.

Empleando la base de datos generada, se creó un modelo sustituto mediante redes neuronales artificiales, considerando los cuatro parámetros de diseño como variables de entrada y los tres indicadores económico-ambientales como variables de salida. A partir de los resultados mostrados en la Tabla 4.1, se observa que la red neuronal artificial con 50 neuronas en la capa oculta presenta los parámetros estadísticos adecuados para representar la integración del sistema SHIP con los colectores de placa plana, con un  $MAPE = 0.1919$ ,  $RMSE = 8.2468 \times 10^{-4}$  y un coeficiente de correlación  $R^2 > 0.9999$  para las tres variables de salida.

Los algoritmos de enjambre de partículas, optimización de ballenas y genético fueron implementados sobre el modelo sustituto para obtener los diagramas de Pareto asociados

a las tres variables de salida. Los valores en las Tablas 4.2 a 4.5 muestran que las cuatro regiones climáticas presentan resultados positivos cuando se emplea diésel como combustible para el calentador auxiliar; para el caso de Coahuila y Jalisco, el gas LP también puede ser empleado. Debido a los VPN negativos, el combustóleo y gas natural no son una opción económicamente viable para ninguna región climática. De los cuatro tipos de clima estudiados, el clima templado es aquel que presenta los mejores indicadores económico-ambientales, seguido de los climas árido, tropical y seco. En estudios previos realizados con colectores de cilindro parabólico (May Tzuc, 2020), no fue posible obtener un escenario favorable para la implementación de dicha tecnología sobre el clima tropical, considerando los cuatro tipos de combustibles para el calentador auxiliar; por tal motivo, cabe destacar la factibilidad económico-ambiental de los colectores solares de placa plana por encima de los colectores de cilindro parabólicos, implementados en la industria láctea para el tipo de clima tropical característico de la ciudad de Mérida, Yucatán. Finalmente, los diagramas de Pareto presentados en las Figuras 4.3 a 4.6 permiten confirmar que los tres algoritmos de optimización empleados presentan prácticamente los mismos conjuntos de soluciones óptimas para cada región climática y tipo de combustible estudiado.

La metodología computacional, caracterizada por el sistema SHIP, el modelo de inteligencia artificial y los algoritmos de optimización, puede ser empleada para analizar la factibilidad económico-ambiental de distintos procesos industriales de los cuales se cuente con las características de demanda térmica. La flexibilidad metodológica permite también la sustitución de la tecnología solar empleada en el presente trabajo por cualquier otra que se desee emplear para suministrar parte del calor demandado, considerando las ecuaciones que rigen el comportamiento térmico y energético del dispositivo.

Las líneas de investigación que continúan a partir del presente trabajo sugieren llevar el análisis a una escala internacional, a fin de determinar los escenarios de factibilidad económico-ambiental para cada tecnología y tipo de combustible en distintas regiones climáticas. Además, el continuo surgimiento de nuevas técnicas de optimización se traduce en novedosas herramientas de trabajo que modificarán la metodología propuesta,

implementándolas en los modelos sustitutos de inteligencia artificial y mejorando de esta manera el tiempo de cómputo requerido, así como la precisión en los cálculos.

## Referencias

- AEE INTEC. (2020). *Solar Heat for Industrial Processes (SHIP) Plants Database*. Retrieved from <http://ship-plants.info/>
- Ascione, F., Bianco, N., De Stasio, C., Mauro, G. M., & Vanoli, G. P. (2017). Artificial neural networks to predict energy performance and retrofit scenarios for any member of a building category: A novel approach. *Energy*, *114*, 999-1017. doi:10.1016/j.energy.2016.10.126
- Bellos, E., & Tzivanidis, C. (2020). Solar-driven polygeneration systems: Recent progress and outlook. *Applied Energy*. doi:10.1016/j.apenergy.2020.114764
- Blair, N., Dobos, A. P., Freeman, J., Neises, T., Wagner, M., Ferguson, T., & Janzou, S. (2014). *System Advisor Model, SAM 2014.4.14: General Description*. doi:10.2172/1126294
- Breen, M., Murphy, M. D., & Upton, J. (2019). Development of a dairy multi-objective optimization (DAIRYMOO) method for economic and environmental optimization of dairy farms. *Applied Energy*, *242*, 1697-1711. doi:https://doi.org/10.1016/j.apenergy.2019.03.059
- Castro, D. M., & Parreiras, F. S. (2018). A Review on Multi-Criteria Decision-Making for Energy Efficiency in Automotive Engineering. *Applied Computing and Informatics*. doi:https://doi.org/10.1016/j.aci.2018.04.004
- Cetina Quiñones, A. J. (2019). *Modelación de un colector solar plano integrado con materiales de cambio de fase*. Tesis de Maestría: Universidad Autónoma de Yucatán.
- Cook, D. F., Ragsdale, C. T., & Major, R. L. (2000). Combining a neural network with a genetic algorithm for process parameter optimization. *Engineering Applications of Artificial Intelligence*, 391-396.

- CRE. (2017). *Comisión Reguladora de Energía - Permisos de Electricidad*. Retrieved from <https://www.gob.mx/crehttps://www.gob.mx/cre/que-hacemoshttp://organodegobierno.cre.gob.mx/permisose.aspx>
- Cui, Y., Geng, Z., Zhu, Q., & Han, Y. (2017). Review: Multi-objective optimization methods and application in energy saving. *Energy*, 125, 681-704.
- Euskal Herriko Unibersitatea. (2019). *Algoritmos Genéticos*. Retrieved from <http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/temageneticos.pdf>
- Galindo-Luna, Y. R., Gómez-Arias, E., Romero, R. J., Venegas-Reyes, E., Montiel-González, M., Karin Unland-Weiss, H. E., . . . Díaz-Salgado, J. (2018). Hybrid Solar-Geothermal Energy Absorption Air-Conditioning System Operating with NaOH-H<sub>2</sub>O - Las Tres Vírgenes (Baja California Sur), La Reforma Case. *Energies*, 11(5), 1268. doi:<https://doi.org/10.3390/en11051268>
- Gandomi, A. H., Alavi, A. H., & Ryan, C. (2015). *Handbook of genetic programming applications*. doi:10.1007/978-3-319-20883-1
- Gaspar Cunha, A., Takahashi, R., Henggeler Antunes, C., & Pereira, F. (2012). Algoritmos genéticos. In *Manual de computação evolutiva e metaheurística*. doi:10.14195/978-989-26-0583-8\_1
- Haykin, S. (2008). *Neural Networks and Learning Machines*. New Jersey, USA: Pearson Prentice Hall. doi:978-0131471399
- Hirunlabh, J., Kongduang, W., Namprakai, P., & Khedari, J. (1999). Study of natural ventilation of houses by a metallic solar wall under tropical climate. *Renewable Energy*, 109-119. doi:10.1016/S0960-1481(98)00783-6
- INECC. (2014). *Factores de emisión para los diferentes tipos de combustibles fósiles que se consumen en México*. Ciudad de México: Instituto Nacional de Ecología y Cambio Climático. Retrieved from



[https://www.gob.mx/cms/uploads/attachment/file/110131/CGCCDBC\\_2014\\_FE\\_tipos\\_combustibles\\_fosiles.pdf](https://www.gob.mx/cms/uploads/attachment/file/110131/CGCCDBC_2014_FE_tipos_combustibles_fosiles.pdf)

- INTEC, A. (2020, 04 20). *Solar Heat for Industrial Processes (SHIP) Plants Database*. Retrieved from <http://ship-plants.info/>
- IRENA. (2015). *Solar Heat for Industrial Processes. Technology Brief*. Estados Unidos: IEA-ETSAP y IRENA.
- Jamshidi, M., Ghaedi, M., Dashtian, K., Ghaedi, A., Hajati, S., Goudarzi, A., & Alipanahpour, E. (2016). Highly efficient simultaneous ultrasonic assisted adsorption of brilliant green and eosin B onto ZnS nanoparticles loaded activated carbon: Artificial neural network modeling and central composite design optimization. *Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy*, 153, 257-267. doi:10.1016/j.saa.2015.08.024
- Kalogirou, S. (2001). Artificial neural networks in renewable energy systems applications: a review. *Renewable and Sustainable Energy Reviews*, 5(4), 373-401. doi:10.1016/S1364-0321(01)00006-5
- Kalogirou, S. A. (2004). Solar thermal collectors and applications. *Progress in Energy and Combustion Science*(30), 231-295. doi:10.1016/j.pecs.2004.02.001
- Kalogirou, S. A. (2009). Solar Energy Collectors. In *Solar Energy Engineering: Processes and Systems* (pp. 121-217). London: Elsevier Academic Press. doi:10.1016/B978-0-12-374501-9.00003-0
- Kennedy, J., & Eberhart, R. C. (1995). Particle swarm optimization. *Proceedings of IEEE International Conference on Neural Networks*, 1942-1948.
- Kumar, L., Hasanuzzaman, M., & Rahim, N. A. (2019). Global advancement of solar thermal energy technologies for industrial process heat and its future prospects: A review. *Energy Conversion and Management*, 195, 885-908. doi:<https://doi.org/10.1016/j.enconman.2019.05.081>

- Lewis, M. J., & Heppel, N. J. (2001). *Continuous thermal processing of foods - pasteurization and uht sterilization*. Maryland, USA: Aspen Publishers, Inc.
- May Tzuc, O. (2020). Optimización económico-ambiental de sistema de concentradores de canal parabólico para calor de proceso industrial mediante herramientas de cómputo avanzado. *Tesis de Doctorado: Universidad Autónoma de Yucatán*.
- May Tzuc, O., Bassam, A., Mendez-Monroy, P. E., & Sanchez Dominguez, I. (2018). Estimation of the operating temperature of photovoltaic modules using artificial intelligence techniques and global sensitivity analysis: A comparative approach. *Journal of Renewable and Sustainable Energy*, 10. doi:10.1063/1.5017520
- Mekhilef, S., Saidur, R., & Safari, A. (2011). A review on solar energy use in industries. *Renewable and Sustainable Energy Reviews*, 15, 1777-1790. doi:10.1016/j.rser.2010.12.018
- Mirjalili, S., & Lewis, A. (2016). The Whale Optimization Algorithm. *Advances in Engineering Software*, 95, 51-67. doi:http://dx.doi.org/10.1016/j.advengsoft.2016.01.008
- Módulo Solar. (2019). *MAXOL Colector solar modelo MS 1.9 UE*.
- Ortega, H. (2018). *Energía solar para procesos industriales en México: Estudio base de mercado*. Retrieved from CONUEE, ANES, GIZ: <https://www.conuee.gob.mx/transparencia/>
- PND. (2019). Rescate del sector energético. In *Plan Nacional de Desarrollo 2019-2024* (pp. 51-52). México: Presidencia de la República.
- Ponce Cruz, P. (2010). *Inteligencia artificial con aplicaciones a la ingeniería*. Ciudad de México: Alfaomega.
- Ramos, C., Ramirez, R., & Beltran, J. (2014). Potential assessment in Mexico for solar process heat applications in food and textile industries. *Energy Procedia*, 49, 1879-1884. doi:10.1016/j.egypro.2014.03.199

- Romero, J. J., Dafonte, C., Gómez, Á., & Ponousal, F. J. (2014). *Inteligencia Artificial y Computación Avanzada*. Retrieved from <https://cdv.dei.uc.pt/wp-content/uploads/2014/03/ms07.pdf>
- SADER. (2018). *Panorama de leche en México*. Ciudad de México: Secretaría de agricultura y desarrollo rural. Retrieved from <http://infosiap.siap.gob.mx/opt/boletlech/PanoramadeLecheoctubre-diciembre2018.pdf>
- Sayyaadi, H. (2009). Multi-objective approach in thermoenviromonic optimization of a benchmark cogeneration system. *Applied Energy*, 86, 867-879. doi:10.1016/j.apenergy.2008.08.017
- Sayyaadi, H., & Baghsheikhi, M. (2018). Developing a novel methodology based on the adaptive neuro-fuzzy interference system for the exergoeconomic optimization of energy systems. *Energy*. doi:10.1016/j.energy.2018.08.202
- Sayyaadi, H., & Baghsheikhi, M. (2019). Retrofit of a steam power plant using the adaptive neuro-fuzzy inference system in response to the load variation. *Energy*, 175, 1164-1173. doi:<https://doi.org/10.1016/j.energy.2019.03.175>
- SE. (2013). *Análisis del sector lácteo mexicano*. Ciudad de México: Secretaría de Economía. Retrieved from <https://www.economia.gob.mx/files/comunidad{ }negocios/industria{ }comercio/informacionSectorial/analisis{ }sector{ }lacteo.pdf>
- SENER. (2018). *Balance Nacional de Energía 2017*. Retrieved from Secretaría de Energía: <https://www.gob.mx/cms/uploads/attachment/file/414843/Balance{ }Nacional{ }de{ }Energ{ }a{ }2017.pdf>
- Sharifzadeh, M., Sikinioti-Lock, A., & Shah, N. (2019). Machine-learning methods for integrated renewable power generation: A comparative study of artificial neural networks, support vector regression, and Gaussian Process Regression. *Renewable*

and *Sustainable Energy Reviews*, 108, 513-538.  
doi:<https://doi.org/10.1016/j.rser.2019.03.040>

- Sharma, A. K., Sharma, C., Mullick, S. C., & Kandpal, T. C. (2015). Carbon mitigation potential of solar industrial process heating: paper industry in India. *Journal of Cleaner Production*, 1-9. doi:<http://dx.doi.org/10.1016/j.jclepro.2015.04.093>
- Sharma, A. K., Sharma, C., Mullick, S. C., & Kandpal, T. C. (2017). Solar industrial process heating: A review. *Renewable and Sustainable Energy Reviews*, 124-137. doi:10.1016/j.rser.2017.04.079
- Sharma, A. K., Sharma, C., Mullick, S. C., & Kandpal, T. C. (2018). Financial viability of solar industrial process heating and cost of carbon mitigation: A case of dairy industry in India. *Sustainable Energy Technologies and Assessments*, 1-8. doi:10.1016/j.seta.2018.03.007
- Sharma, A., Sharma, C., Mullick, S., & Kandpal, T. (2016). Carbon mitigation potential of solar industrial process heating: paper industry in India. *Journal of Cleaner Production*(112), 1683-1691.
- Short, W., Packey, D. J., & Holt, T. (1995). A manual for the economic evaluation of energy efficiency and renewable energy technologies. doi:NREL/TP-462-5173
- Slowik, A. (2018). Particle Swarm Optimization. In B. Chopard, & M. Tomassini, *An Introduction to Metaheuristics for Optimization* (pp. 97-102). doi:10.1007/978-3-319-93073-2\_6
- Solar Payback. (2018). *Calor solar para la industria: México*. Retrieved from [https://www.solar-payback.com/wp-content/uploads/2018/06/Solar-Payback\\_Calor-Solar-para-la-Industria\\_Mexico.pdf](https://www.solar-payback.com/wp-content/uploads/2018/06/Solar-Payback_Calor-Solar-para-la-Industria_Mexico.pdf)
- Starke, A. R., Cardemil, J. M., Escobar, R., & Colle, S. (2018). Multi-objective optimization of hybrid CSP+PV system using genetic algorithm. *Energy*. doi:10.1016/j.energy.2017.12.116

The Mathworks Inc. (2014). *Global Optimization Toolbox User's Guide R2014b*.

Vargas-López, R., Xamán, J., Hernández-Pérez, I., Arce, J., Zavala-Guillén, I., Jiménez, M. J., & Heras, M. R. (2018). Mathematical models of solar chimneys with a phase change material for ventilation of buildings: A review using global energy balance. *Energy*. doi:10.1016/j.energy.2018.12.148

Viñuela, P. I., & León, I. G. (2004). *Redes neuronales artificiales: Un enfoque práctico*. Retrieved from Pearson Educación: <https://books.google.com.mx/books?id=izJ6NQAACAAJ>

# Anexo 1

```

% Modelación del colector solar de placa plana modelo MS 1.9 UE
% de la marca Módulo Solar, en estado estacionario

clc;
clear all;

% Constantes
g=9.81; % gravedad (m/s^2)
e_g=0.90; % emisividad de la cubierta (-)
e_p=0.95; % emisividad de la placa absorbadora (-)
e_bt=0.25; % emisividad de la placa parte superior (-)
e_bb=0.25; % emisividad de la cubierta inferior (-)
sigma=5.67E-8; % constante de Stefan-Boltzmann (-)
v=3.6E-4; % viscosidad del fluido
df=0.019; % diámetro del fluido
alfa_g=0.06; % absorptividad de la cubierta (-)
alfa_p=0.95; % absorptividad de la placa absorbadora (-)
tau_g=0.84; % transmisividad de la cubierta (-)
d_a=0.254; % separación de la cubierta y la placa (m)
d_i=0.025; % espesor del aislante (m)
d_f=0.0254; % separación de la placa absorbadora y el aislante (m)
k_i=0.01; % conductividad termica del aislante (W/m K)
phi=30; % inclinación de colector (°)
G=1000; % radiación solar
v=0; % velocidad del viento (m/s)
L=2.045; % longitud del colector (m)
w=0.931; % ancho del colector (m)
m_f=2.007; % flujo másico (kg/s)
Dh=2*d_f; % diámetro hidráulico (m)
divL=10; % número de secciones (-)

% Inicialización de matrices
A=zeros(4,4); % matriz de coeficientes
B=zeros(4,1); % vector resultante
T_prop=zeros(4,divL); % matriz de temperaturas propuestas
T_new=zeros(4,divL); % matriz de temperaturas nuevas
T_final=zeros(4,divL); % matriz de temperaturas por nodo
T_fin=zeros(1,divL); % matriz de temperaturas iniciales del fluido
T_fout=zeros(1,divL); % matriz de temperaturas de salida del fluido

% Temperaturas propuestas
T_amb=24+273.15; % temperatura ambiente (K)
T_sky=0.0552*(T_amb^1.5); % temperatura del cielo (K)
T_prop(1,1)=35+273.15; % temperatura de la cubierta de vidrio (T_g) (K)
T_prop(2,1)=65+273.15; % temperatura de la placa absorbadora (T_p) (K)

```

```

T_prop(3,1)=30+273.15; % temperatura del fluido (T_f) (K)
T_prop(4,1)=32+273.15; % temperatura del aislante (T_i) (K)
T_fin(1,1)=30+273.15; % temperatura inicial del fluido (T_fin) (K)

% Propiedades ópticas del colector
tau=tau_g;
alpha=alfa_p;

for i=1:(divL/10):divL

    % Malla espacial
    dx(i)=L/divL; % longitud por sección (m)
    x(i)=(i-1)*dx(i)+(dx(i)/2);

    error=0.0001;
    delta=1;

    if(i>1)
        T_prop(1,i)=T_new(1,i-1);
        T_prop(2,i)=T_new(2,i-1);
        T_prop(3,i)=T_new(3,i-1);
        T_prop(4,i)=T_new(4,i-1);
    end

    while (delta>error)

        % Propiedades físicas del aire interno
        T_mean1=(T_prop(1,i)+T_prop(2,i))/2; % temperatura promedio para evaluar las propiedades
del aire (K)
        visc_din_a=(1.983+(0.00184*(T_mean1-T_amb)))*1E-5; % viscosidad dinámica del aire (kg/m
s)
        rho_a=1.1774-(0.00359*(T_mean1-T_amb)); % densidad del aire (kg/m^3)
        k_a=0.02624+(0.0000758*(T_mean1-T_amb)); % conductividad térmica del aire (w/m K)
        cp_a=(1.0057+(0.000066*(T_mean1-T_amb)))*1E3; % calor específico del aire (J/kg K)
        visc_cin_a=visc_din_a/rho_a; % viscosidad cinemática del aire (m^2/s)
        dif_a=k_a/(rho_a*cp_a); % difusividad térmica del aire (m^2/s)
        Pr_a=visc_cin_a/dif_a; % número de Prandtl del aire (-)

        % Cálculo de h_conv_nc (convección interna del aire)
        beta=1/T_mean1; % coeficiente de expansión del aire (1/K)
        Ra=(g*beta*abs(T_prop(2,i)-T_prop(1,i))*(d_a^3))/(visc_cin_a*dif_a); % número de
Rayleigh del aire (-)

        CRA_1=1708./(Ra*(cosd(phi)));
        CRA_2=(sind(1.8*phi))^1.6;
        CRA_3=((Ra*(cosd(phi)))/5830)^(1/3);
        CRA_4=1.44*(1-(CRA_1*CRA_2));
        CRA_5=1-CRA_1;
        CRA_6=CRA_3-1;

```

```

    if(CRa_5<0)
    CRA_5=0;
    end

    if(CRa_6<0)
    CRA_6=0;
    end

    Nu_a=1+(Cra_4*Cra_5)+Cra_6; % número de Nusselt del aire interno (-)

    % Coeficientes de convección y radiación
    h_conv_nc=(Nu_a*k_a)/d_a; % coeficiente de pérdida de calor por convección (W/m^2 K)

    h_rad_pg=(sigma*(T_prop(1,i)^2+T_prop(2,i)^2)*(T_prop(1,i)+T_prop(2,i)))/((1/e_g)+(1/e_p)-1); %
    coeficiente de pérdida de calor por radiación de la cubierta a la placa (W/m^2 K)

    h_rad_pb=(sigma*(T_prop(2,i)^2+T_prop(4,i)^2)*(T_prop(2,i)+T_prop(4,i)))/((1/e_bt)+(1/e_bb)-1); %
    coeficiente de pérdida de calor por radiación de la placa a la cubierta inferior (W/m^2 K)
    h_sky=0.3358; % coeficiente de pérdida de calor por radiación de la cubierta al cielo
    (W/m^2 K)
    h_wind=5.7+(3.8*v); % coeficiente de pérdida de calor por convección de la cubierta al
    ambiente (W/m^2 K)

    % Coeficientes globales
    U_t=h_wind+h_sky; % coeficiente global de pérdida de calor de la cubierta con el entorno
    (W/m^2 K)
    U_b=1/((d_i/k_i)+(1/h_wind)+(d_i/k_i)); % coeficiente global de pérdida de calor por
    conducción del aislante con el ambiente (W/m^2 K)

    % Propiedades del fluido
    visc_din_f=(1.983+(0.00184*(T_prop(3,i)-T_amb)))*1E-5; % viscosidad dinámica del fluido
    (kg/m s)
    rho_f=1.1774-(0.00359*(T_prop(3,i)-T_amb)); % densidad del fluido (kg/m^3)
    k_f=0.02624+(0.0000758*(T_prop(3,i)-T_amb)); % conductividad térmica del fluido (W/m K)
    visc_cin_f=visc_din_f/rho_f; % viscosidad cinemática del fluido (m^2/s)
    cp_f=4.2; % calor específico del fluido (J/kg K)
    dif_f=k_f/(rho_f*cp_f); % difusividad térmica del fluido (m^2/s)
    visc_din_w=(1.983+(0.00184*(T_fin(i)-T_amb)))*1E-5; % viscosidad dinámica del fluido
    evaluado en la pared del ducto (kg/m s)

    Re=(4*m_f)/(pi*d_f*v); % número de Reynolds (-)

    % Cálculo de h_conv_f

    if(Re<=2300)
    Pr_f=0.7;
    CNuf_1=(Re*Pr_f*(Dh/x(i)))^1.71;
    CNuf_2=(Re*Pr_f*(Dh/x(i)))^1.17;
    Nu_f=5.4+((0.0019*CNuf_1)/(1+(0.00563*CNuf_2))); % número de Nusselt del fluido (-)
    h_conv_f=Nu_f*k_f/Dh; % coeficiente de pérdida de calor por convección del fluido
    (W/m^2 K)

```



```

elseif(Re>2300 && Re<=10000)
    Pr_f=visc_cin_f/dif_f; % número de Prandtl del fluido (-)
    CNUf_1=0.116*((Re^(2/3))-125)*(Pr_f^(1/3));
    CNUf_2=(1+((Dh/x(i))^(2/3)))*((visc_din_f./visc_din_w)^0.14);
    Nu_f=CNUf_1+CNUf_2;
    h_conv_f=Nu_f*k_f/Dh;
elseif(Re>10000)
    Pr_f=visc_cin_f/dif_f; % número de Prandtl del fluido (-)
    CNUf_1=0.023*(Re^0.8)*(Pr_f^(1/3));
    Nu_f=CNUf_1;
    h_conv_f=Nu_f*k_f/Dh;
end

Gamma=(2*m_f*cp_f)/(w*dx(i)); % parámetro de calor útil
S1=alfa_g*G; % radiación aprovechada en la cubierta (W/m^2)
S2=tau_g*alfa_p*G; % radiación aprovechada en la placa absorbadora (W/m^2)

% Matriz de coeficientes y vector resultante

A(1,1)=(h_rad_pg+h_conv_nc+U_t);
A(1,2)=-(h_rad_pg+h_conv_nc);
A(1,3)=0;
A(1,4)=0;
B(1)=S1+(U_t*T_amb);

A(2,1)=-(h_rad_pg+h_conv_nc);
A(2,2)=(h_rad_pg+h_conv_nc+h_rad_pb+h_conv_f);
A(2,3)=-h_conv_f;
A(2,4)=-h_rad_pb;
B(2)=S2;

A(3,1)=0;
A(3,2)=-h_conv_f;
A(3,3)=(2*h_conv_f+Gamma);
A(3,4)=-h_conv_f;
B(3)=Gamma*T_fin(i);

A(4,1)=0;
A(4,2)=-h_rad_pb;
A(4,3)=-h_conv_f;
A(4,4)=(h_rad_pb+h_conv_f+U_b);
B(4)=U_b*T_amb;

X=A\B;

T_new(1,i)=X(1);
T_new(2,i)=X(2);
T_new(3,i)=X(3);
T_new(4,i)=X(4);

for j=1:4

```

```

delta(j)=abs(T_new(j,i)-T_prop(j,i));

    if (delta>error)
        T_prop(1,i)=T_new(1,i);
        T_prop(2,i)=T_new(2,i);
        T_prop(3,i)=T_new(3,i);
        T_prop(4,i)=T_new(4,i);
    else
        T_final(1,i)=T_new(1,i);
        T_final(2,i)=T_new(2,i);
        T_final(3,i)=T_new(3,i);
        T_final(4,i)=T_new(4,i);
    end
end
end

U_l=U_t+U_b;
d_f_t=0.0254; % diámetro de cada tubo
d_f_i=0.9*d_f_t; % diámetro interno de cada tubo
w_f=d_f_t+0.01; % separación entre cada tubo
d_p=0.0254; % grosor de la placa absorbidora
k_p=385; % conductividad de la placa absorbidora
m=sqrt(U_l/(k_p*d_p));
F=(tanh((m*(w_f-d_f_t))/2))/((m*(w_f-d_f_t))/2);
F_prima=(1./U_l)/(w_f*((1/(U_l*(d_f_t+F*(w_f-d_f_t)))+(1/(pi*d_f_i*h_conv_f))));
F_r=((m_f.*cp_f)./(L.*w.*U_l)).*(1+exp(-(U_l.*F_prima.*L.*w)./(m_f.*cp_f)));

T_fout(1,i)=(2*T_final(3,i))-T_fin(1,i); % temperatura de salida del fluido (K)
T_fin(1,i+1)=T_fout(1,i); % temperatura de entrada del fluido (K)
DeltaT1=T_final(3,i)-T_amb;
eff(i)=F_r.*tau*alpha-F_r.*U_l*((T_final(3,i)-T_amb)./G); % eficiencia instantánea (-)
ejexeff(i)=(T_final(3,i)-T_amb)./G; % eje x para validar el datasheet
E(i)=eff(i).*L.*w.*G; % energía [W]
end

T_f1=[24 29 34 39 44 49 54 59 64 69 74 79 84 89 94 99 104 109 114]; % temperatura del fluido para el
eje x
T_f2=[57.0833 55.6933 54.3033 52.9133 51.6133 50.3133 49.0133 47.7133 46.4133 45.1133 43.8133
42.5133 41.2133 39.9133 38.6133 37.3133 36.0133 34.7133 33.4523]; % temperatura del fluido para la
eficiencia
T_amb1=24;
DeltaT2=T_f2-T_amb1; % diferencia de temperatura para la eficiencia

% Conversión de temperaturas, de K a °C
T_final-273.15;
T_fout-273.15;
T_fin-273.15;
eff;

ejex=0:L/9:L;

```

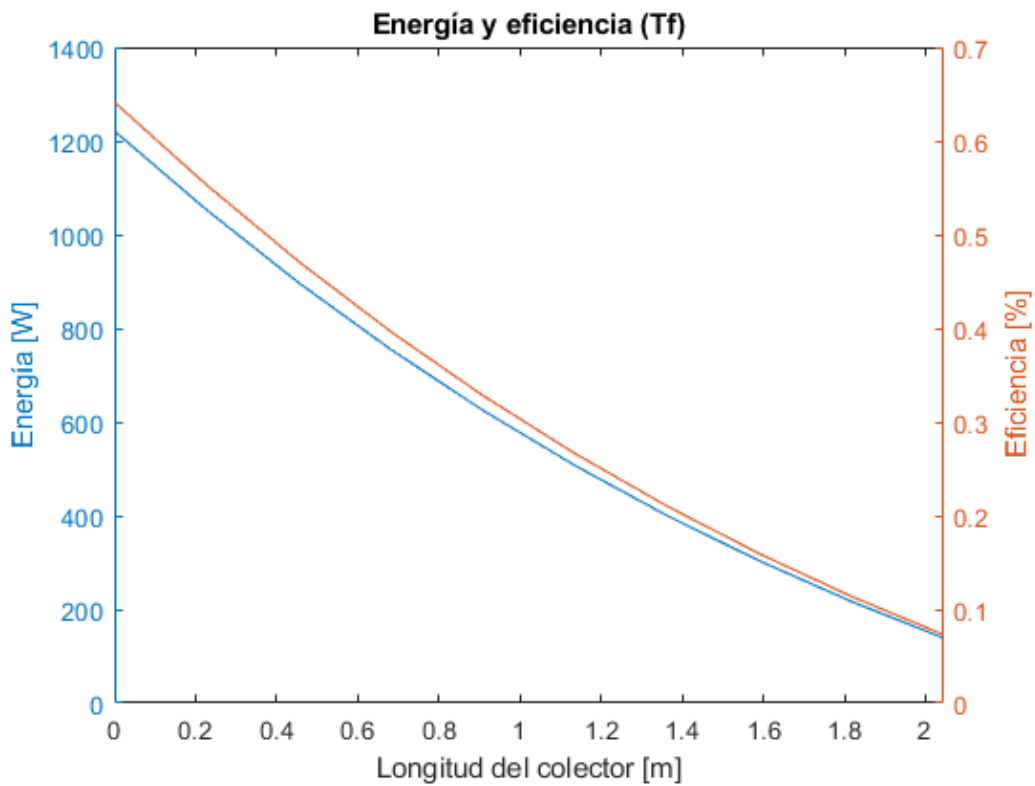
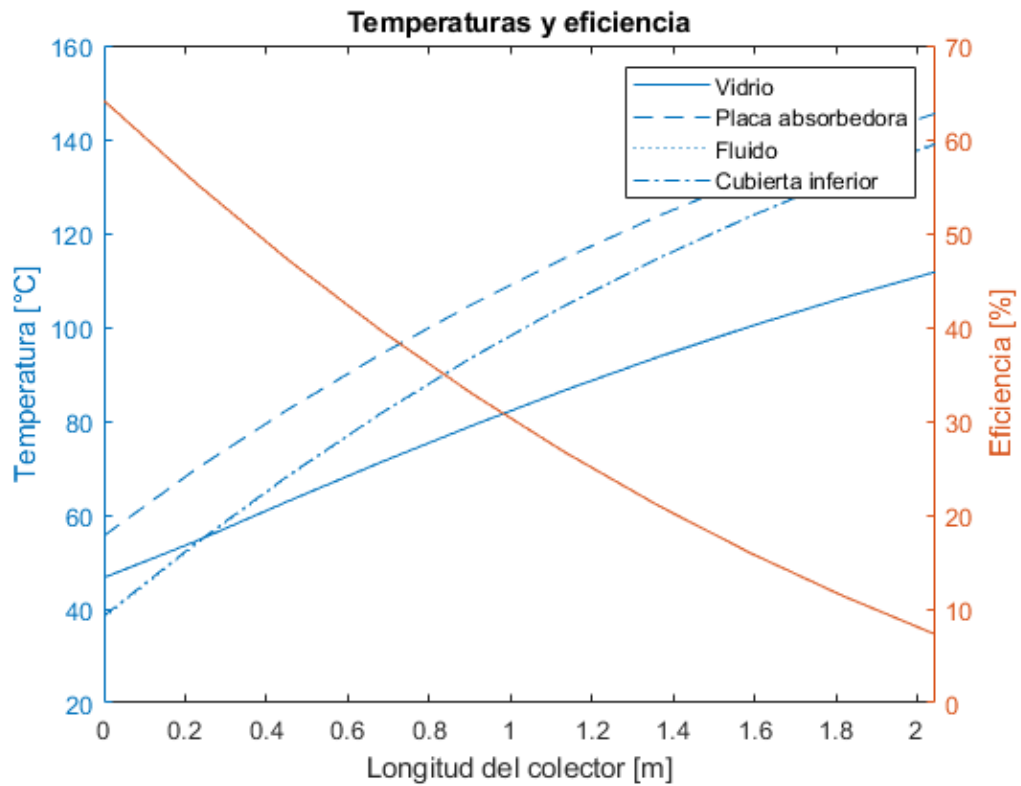
```
figure(1)
yyaxis left
plot(ejex,T_final-273.15)
ylabel('Temperatura [°C]');

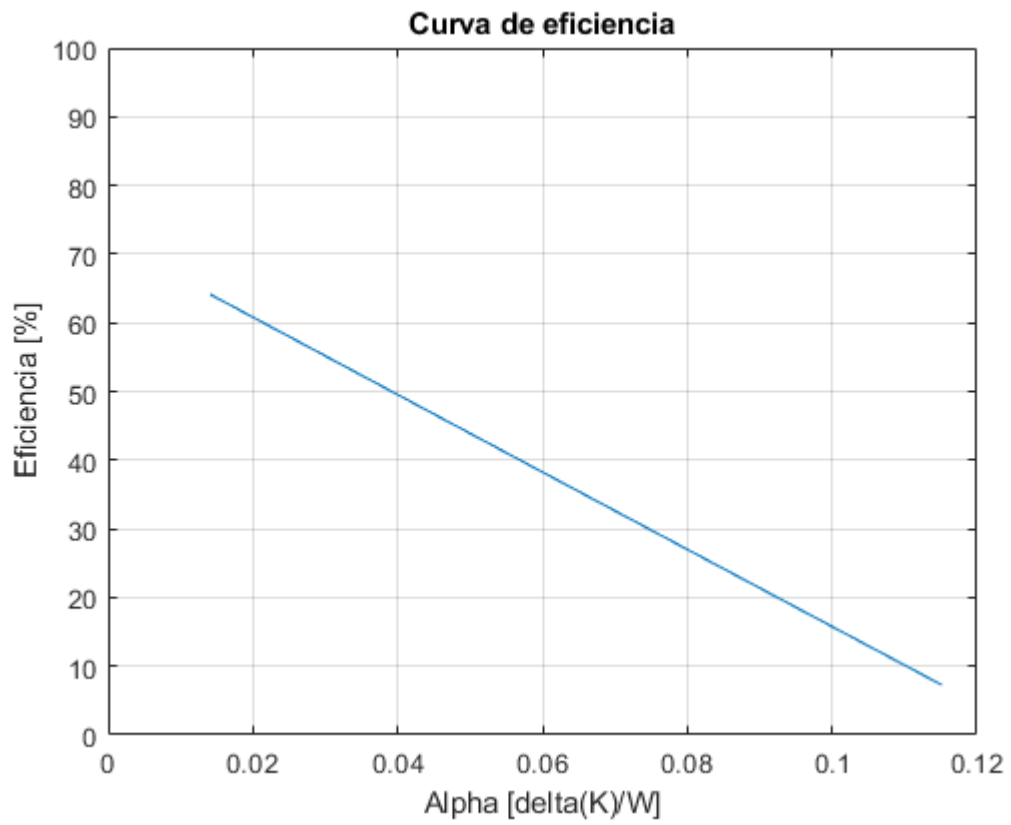
yyaxis right
plot(ejex,eff*100)
ylabel('Eficiencia [%]');
xlabel('Longitud del colector [m]')
title('Temperaturas y eficiencia')
xlim([0 L]);
legend('Vidrio','Placa absorbedora','Fluido','Cubierta inferior');
```

```
figure(2)
yyaxis left
plot(ejex,E)
ylabel('Energía [W]');

yyaxis right
plot(ejex,eff)
ylabel('Eficiencia [%]');
xlabel('Longitud del colector [m]')
title('Energía y eficiencia (Tf)')
xlim([0 L]);
```

```
figure(3)
plot(ejex,eff*100)
ylabel('Eficiencia [%]');
xlabel('Alpha [delta(k)/w]')
title('Curva de eficiencia');
ylim([0 100]);
xlim([0 0.120]);
grid on
```





*[Published with MATLAB® R2018a](#)*

## Anexo 2

Participación y obtención del segundo lugar en las sesiones orales correspondientes al Congreso Nacional de Estudiantes de Energías Renovables 2021 (CNEER), celebrado en línea del 29 al 31 de marzo del 2021, con el trabajo titulado: “Implementación de redes neuronales artificiales para la simplificación de cálculos económicos y ambientales en plantas termosolares: Caso de estudio de la industria láctea en Jalisco”



## Reconocimiento

### El Instituto de Energías Renovables de la Universidad Nacional Autónoma de México

otorga el siguiente reconocimiento a

**Víctor Cardoso Fernández, Oscar de Jesús May Tzuc, Ali Bassam, Francisco Noe Demesa López, Ignacio Vicente Pérez Quintana y Luis José Ricalde Castellanos**

por haber obtenido el **Segundo Lugar** en el concurso de **Sesión Oral** con el trabajo:

*Implementación de redes neuronales artificiales para la simplificación de cálculos económicos y ambientales en plantas termosolares: Caso de estudio de la industria láctea en Jalisco*

**Congreso Nacional de Estudiantes de Energías Renovables 2021**

realizado los días 29, 30 y 31 de marzo de 2021

  
M. en I. Miguel Ángel Alvarado Morales  
Coordinador General  
CNEER 2021

  
Demian Uriel Bazán Anaya  
Coordinador Diseño y Difusión  
CNEER 2021

