

UNIVERSIDAD MICHOACANA DE SAN NICOLÁS DE HIDALGO
DIVISIÓN DE ESTUDIOS DE POSGRADO
FACULTAD DE INGENIERÍA QUÍMICA

DESARROLLO DE MODELOS DE OPTIMIZACIÓN Y SU
APLICACIÓN EN EL DISEÑO DE EQUIPO Y
PROCESOS PRODUCTIVOS

TESIS

Presentada por

JAVIER TOVAR FACIO

A la División de Estudios de Posgrado
de la Facultad de Ingeniería Química
como requisito parcial para obtener el grado de

DOCTOR EN CIENCIAS EN INGENIERÍA QUÍMICA

Dirigido por:

JOSÉ MARÍA PONCE ORTEGA



Morelia, Michoacán. Agosto 2020

Resumen

En este trabajo se presentan tres diferentes aplicaciones de los modelos de optimización en lo que respecta al diseño de equipo y a la planeación de procesos productivos. Se incluyen modelos deterministas y estocásticos del tipo no lineal y mixto entero lineal y se utilizan los lenguajes algebraicos de modelado GAMS y JuMP para formularlos y obtener una solución mediante *solvers* como IPOPT y GUROBI. Como primer caso se estudiaron diferentes estrategias para abordar problemas de programación no lineales (NLP) con restricciones probabilísticas utilizando el diseño de un sistema de antorchas para ilustrar diferentes metodologías. Se demostró que la aproximación sigmoidea reduce significativamente el sobredimensionamiento de aproximaciones populares, como el valor condicional en el riesgo y el enfoque basado en escenario, logrando una reducción en el costo del equipo de hasta 64%. En segundo lugar, se estudió el efecto de la monetización de gases de efecto invernadero para promover la reducción de los gases combustibles de desecho (GCD). Se propuso diseñar un sistema de cogeneración que utilice gas natural como combustible principal y GCD como combustible complementario. El factor clave para minimizar las emisiones de dióxido de carbono es el reemplazo de gas natural con GCD. Se compararon tres casos, que consideran diferentes métodos para fomentar el uso de GCD. Los resultados muestran que cuando se utiliza el enfoque basado en una solución de compromiso se alcanza una disminución de emisiones del 85% sin la necesidad de penalizaciones o incentivos económicos. Finalmente, se abordó la selección óptima de la estructura de generación de energía renovable necesaria para sustituir plantas de potencia existentes en un sistema eléctrico a gran escala. Se desarrolló un modelo de optimización mixto entero lineal multiobjetivo que puede ser adaptado a diferentes sistemas de generación eléctrica nacionales. Se presenta un caso de estudio del Sistema Eléctrico Peninsular de España debido a que se avecina el desmantelamiento de sus centrales térmicas nucleares y de carbón. La transición energética propuesta alcanza una reducción en las emisiones del 49.7% y se disminuye la intensidad del consumo de agua en un 37.5%.

Palabras Clave: Desarrollo sustentable; restricciones probabilísticas; optimización multiobjetivo; monetización de emisiones; transición energética.

Abstract

This work presents three different applications of optimization models to design industrial equipment and production processes. Non-linear and mixed integer linear programming models are included considering deterministic and stochastic approaches. The algebraic modeling languages GAMS and JuMP were used to formulate the models and to find a solution using solvers such as IPOPT and GUROBI. In the first case study, we analyzed different strategies to address non-linear programming (NLP) problems with chance constraints using the design of a flare system to study different methodologies. The results show that the sigmoidal approximation significantly reduces the equipment oversizing of popular approximations, such as the conditional value at risk and the scenario-based approach. A reduction in equipment cost of up to 64% is achieved. In the second case, it was studied the effect of greenhouse gas monetization to promote the reduction of waste fuel gases (WFG). It was proposed to design a cogeneration system that uses natural gas as a main fuel and WFG as a supplementary fuel. The key factor is the replacement of natural gas with WFG to minimize carbon dioxide emissions. Three scenarios were compared considering different methods to promote the use of WFG. The results show that the approach based on a compromised solution reduces emission 85% and there is no need for taxes or financial incentives. Finally, the optimal mix of the renewable energy to substitute existing power plants in a large-scale electrical system was addressed. A multiobjective linear integer mixed optimization model that can be adapted to different national electricity systems was developed. A case study of the Peninsular Electricity System of Spain was chosen due to the imminent decommission of its nuclear and coal thermal power plants. The proposed energy transition reaches a reduction in emissions of 49.7% and the intensity of water consumption is reduced by 37.5%.

A mi madre
Ma. Elvira Facio Pérez

Agradecimientos

- Agradezco en primer lugar al Dr. José María Ponce Ortega por darme la invaluable oportunidad de realizar mi Tesis de Doctorado bajo su dirección, por su apoyo incondicional durante todos mis estudios de posgrado, por su excelente enseñanza y por el apoyo que me brindó para asistir a congresos (nacionales e internacionales), realizar estancias de investigación en el extranjero y publicar nuestra investigación en revistas de alto impacto.
- Al Dr. Fabricio Nápoles Rivera por el gran apoyo que me brindó y el conocimiento que compartió durante las colaboraciones que tuvimos. También, por la vital ayuda y confianza que me brindo cuando participé en diferentes convocatorias durante mis estudios de posgrado y por la guía que me brindo cada semestre hasta la culminación de esta Tesis.
- Al Dr. Víctor M. Zavala de la Universidad de Wisconsin-Madison por la oportunidad de realizar una estancia de investigación bajo su dirección y por el apoyo económico que se me otorgó.
- Al Dr. Mariano Martín de la Universidad de Salamanca por permitirme integrarme a su excelente grupo de investigación PSEM3 y por el gran soporte que le ha dado a mi desarrollo profesional.
- Al Dr. Mahmoud M. El-Halwagi de la Universidad de Texas A&M por recibirme en su grupo de investigación y por la oportunidad de colaborar con él en 3 publicaciones.
- Al Dr. Medardo Serna González por sus comentarios en los seminarios semestrales y sobre todo por alentarme a estudiar un posgrado y recomendarme con el Dr. José María Ponce Ortega.
- Al Dr. Fernando Lira Barragán por compartir sus conocimientos cuando colaboramos en una publicación y por la retroalimentación que me brindó en cada seminario.
- Al Dr. Luis Fabian Fuentes Cortes por darme la oportunidad de colaborar con él y por tomarse el tiempo de enseñarme a utilizar LaTeX y JuMP/Julia.

- Agradezco a la Universidad Michoacana de San Nicolás de Hidalgo y la Facultad de Ingeniería Química por abrirme sus puertas para y permitirme cursar un posgrado del PNPC en sus aulas y por el apoyo económico que me brindó a lo largo de mi doctorado.
- A la Universidad de Wisconsin-Madison, a la Universidad de Texas A&M y a la Universidad de Salamanca por recibirme y darme una atención notable durante mis estancias de investigación.
- A la Fundación Telmex-Telcel por la Beca para estudiantes de excelencia académica de nivel posgrado que me otorgó.
- A la Secretaría General Iberoamericana y a Fundación Carolina por concederme la Beca SEGIB-Fundación Carolina para estancias internacionales de investigación.
- Al Concejo Nacional de Ciencia y Tecnología por el apoyo económico para realizar mis estudios de posgrado y estancias en el extranjero.

Contenido

Resumen	iii
Abstract	iv
Agradecimientos	vi
Contenido	viii
Índice de Figuras	x
Índice de Tablas	xii
Capítulo 1. Introducción	1
1.1 Hipótesis	3
1.2 Objetivos	3
Capítulo 2. Marco teórico	4
2.1 Modelos de optimización	4
2.2 Clasificación de los problemas de optimización	6
2.3 Optimización lineal	8
2.4 Optimización no lineal	9
2.5 Optimización mixta entera lineal	9
2.6 Optimización mixta entera no lineal	11
2.7 Optimización estocástica con recurso	12
2.8 Optimización estocástica con restricciones probabilísticas	14
2.9 Optimización Multiobjetivo	29
Capítulo 3. Diseño de equipo, problemas NLP con restricciones probabilísticas	34
3.1 Diseño de antorchas (<i>Flare Systems</i>)	35

Capítulo 4. Diseño de equipo y políticas de carbono, problemas NLP multiobjetivo	47
4.1 Análisis de precios de carbono en proyectos de mitigación de emisiones	48
Capítulo 5. Procesos productivos, problemas MILP multiobjetivo	64
5.1 Transición energética sustentable	65
Conclusiones	95
Apéndice	98
Publicaciones derivadas de este documento	98
Publicaciones no reportadas en este documento	99
Otras publicaciones	100
Bibliografía	101

Índice de Figuras

Figura 2.1: Actividades principales en la formulación de un modelo	5
Figura 2.2: Aproximación conservadora de la función indicadora usando funciones sigmoideas	27
Figura 2.3: Desviaciones del objetivo	32
Figura 3.1: Esquema general de una antorcha	37
Figura 3.2: PDF del flujo de alimentación asumiendo distribución log-normal (arriba-izquierda); PDF de la radiación usando MM (arriba-derecha); PDF de la radiación usando CVaR (abajo-izquierda); PDF de la radiación usando SigVaR (abajo-derecha)	43
Figura 3.3: PDF del flujo de alimentación asumiendo distribución exponencial (arriba-izquierda); PDF de la radiación usando MM (arriba-derecha); PDF de la radiación usando CVaR (abajo-izquierda); PDF de la radiación usando SigVaR (abajo-derecha)	44
Figura 3.4: CDF de la radiación cuando se asume una distribución log-normal (izquierda); CDF de la radiación cuando se asume una distribución exponencial. Resultados de MM (derecha)	45
Figura 3.5: CDF para la radiación cuando el flujo de alimentación sigue una distribución Log-Normal (izquierda). CDF para la radiación cuando el flujo de alimentación sigue una distribución Exponencial (derecha)	46
Figura 4.1: Superestructura del sistema propuesto	52
Figura 4.2: Puntos de referencia	59
Figura 4.3: Resultados de los diferentes precios en el comercio de emisiones (Caso 1)	60
Figura 4.4: Resultados utilizando penalizaciones económicas por la generación de emisiones (Caso 2)	61
Figura 4.5: Resultados de la solución compromiso (Caso 3)	62

Figura 5.1: Superestructura de la transición energética propuesta	68
Figura 5.2: Factor de planta promedio de las diferentes tecnologías que integran el SEPE (2014 – 2019)	81
Figura 5.3: Demanda mensual de electricidad en el SEPE para diferentes años (2014 – 2019)	83
Figura 5.4: Ejemplo del seguimiento de la demanda de electricidad en el SEPE, enero 30–31, 2020	84
Figura 5.5: Discretización de la demanda en periodos de día y de noche	84
Figura 5.6: a) Estructura de generación optima utilizando la función multiobjetivo propuesta. b) Estructura de generación del SEPE en 2019	86
Figura 5.7: Localización y capacidades requeridas de las nuevas plantas de energía renovable. minimización del costo anual total	88
Figura 5.8: Estructura de generación del SEPE. Minimización del costo anual total	88
Figura 5.9: Capacidad requerida y localización de las energías renovables. Minimización de la función multiobjetivo	90
Figura 5.10: Estructura de generación del SEPE. Minimización de la función multiobjetivo	91
Figura 5.11: Capacidad requerida y localización de las energías renovables. TRADE-off A	92
Figura 5.12: Estructura de generación del SEPE. TRADE-off A	93
Figure 5.13: Capacidad requerida y localización de las energías renovables. TRADE-off B.	94
Figure 5.14: Estructura de generación del SEPE. TRADE-off B.	94

Índice de Tablas

Tabla 2.1: Diferentes combinaciones de las variables de holgura.	32
Tabla 3.1: Valores óptimos de las variables de diseño cuando el flujo de alimentación sigue una distribución Log-Normal	42
Tabla 3.2: Valores óptimos de las variables de diseño cuando el flujo de alimentación sigue una distribución Exponencial	42
Tabla 4.1: Valores de estímulos económicos usados	56
Tabla 4.2: Valores de penalizaciones económicas usadas	56
Tabla 4.3: Prioridades de los objetivos para la ecuación multiobjetivo	57
Tabla 4.4: Propiedades de las corrientes usadas en el análisis	58
Tabla 4.5: Composición de los GCD	58
Tabla 5.1: Dióxido de carbono equivalente generado por cada tecnología	82
Tabla 5.2: Resumen de los resultados económicos y ambientales	86

Capítulo 1

Introducción

En este capítulo se presenta un panorama general de este trabajo. Además, se justifica la importancia de los modelos de optimización cuando se busca resolver problemas en ingeniería y se plantean los objetivos principales de la investigación.

En este trabajo se presenta la formulación de modelos de optimización, tanto deterministas como estocásticos, con diferentes aplicaciones. Formular estos modelos de optimización es quizá el paso más crucial en la optimización. La formulación de problemas requiere identificar los elementos esenciales de un sistema para una determinada aplicación y organizarlos en una forma matemática conocida que incluya [1]:

1. Una función objetivo
2. Las restricciones del sistema

La formulación del modelo dependerá de los intereses que se tengan, ya sean económicos, técnicos, ambientales, sociales, de seguridad o una combinación de varios de ellos. Cuando se tiene el modelo definido se utilizan métodos específicos para encontrar la mejor solución posible y la selección del método de solución dependerá de las características del modelo formulado. Posteriormente, se realizan los cálculos para encontrar la solución óptima de las variables de decisión, pero para lograrlo se requiere de un gran número de operación que crece en función del tamaño y las operaciones entre variables que tienen las restricciones.

Afortunadamente, desde la aparición de los equipos de cómputo se potenció la capacidad de realizar cálculos y por ello la optimización ha tenido numerosas aplicaciones en ingeniería química y muchas otras áreas del conocimiento. Por ejemplo, en problemas de planeación de producción [2], cadena de suministro [3], localización y transporte [4], asignación de recursos [5], diseño de equipo [6], etcétera. La tecnología con la que se cuenta hoy en día permite resolver problemas más complejos o inclusive replantear problemas para encontrar mejores y más robustas soluciones. Prueba de ello es la capacidad de resolver problemas Mixtos Enteros Lineales (MILP), No Lineales (NLP) y Mixtos Enteros No Lineales (MINLP) con millones de variables [7], [8] o considerar incertidumbre en problemas de optimización utilizando programación estocástica [9]–[11]. En el caso de los problemas de gran escala se pueden considerar sistemas completos que incluyan simultáneamente el diseño de equipo, la cadena de suministro, la planeación, etc. Por otro lado, la principal ventaja de utilizar programación estocástica para resolver problemas de optimización es que se puede ofrecer una solución que considere varios escenarios, es decir, parámetros inciertos que cambian con el tiempo o que presentan un comportamiento difícil de predecir exactamente, tales como, la demanda de algún producto o servicio, la temperatura del ambiente o el precio de alguna materia prima.

La implementación y solución de estos modelos es posible gracias a lenguajes de modelado para programación matemática como GAMS [12], AMPL [13], PYOMO [14] y JuMP [15] que permiten codificar los modelos en un lenguaje algebraico y que actúan como una interfase automática con *solvers* LP, MINL, NLP, MINLP, etc.

Los modelos que se desarrollaron en esta Tesis fueron codificados en GAMS y en JuMP. Entre ellos se incluyen modelos del tipo NLP, estocástico NLP, NLP con restricciones probabilísticas y MILP. Además, se colaboró en la formulación de modelos MINLP y estocásticos MILP que no se encuentran descritos en este documento, pero su respectiva referencia puede ser consultada en el apéndice de este documento.

La estructura de esta Tesis se compone de los siguientes capítulos: El Capítulo 2 presenta el marco teórico sobre la optimización y presenta algunas de las aplicaciones que se han desarrollado en ingeniería química y otras áreas del conocimiento. Los Capítulos 3, 4 y 5 presentan el desarrollo, implementación y los resultados de los diferentes modelos matemáticos que se presentan en este trabajo. El Capítulo 3 aborda un problema sobre diseño

de equipo considerando optimización no lineal con restricciones probabilísticas. El Capítulo 4 estudia el efecto de utilizar un enfoque de optimización mono objetivo contra una solución compromiso multiobjetivo con diferentes niveles de prioridad en objetivos económicos y ambientales. El Capítulo 5 aborda el tema de la transición energética utilizando un modelo de optimización mixto entero lineal para la selección de la estructura de generación óptima en sistemas de generación de potencia eléctrica de gran escala considerando múltiples objetivos. Finalmente, en el Capítulo 6 se muestran las conclusiones de este trabajo de Tesis.

1.1 Hipótesis

El desarrollo de modelos de optimización para el diseño óptimo de equipo, sistemas de distribución de energía, cadenas de suministro y otros procesos productivos permitirá brindar soluciones sustentables y obtener información útil para los tomadores de decisiones.

1.2 Objetivos

1.2.1 Objetivo General

Desarrollar modelos de optimización que permitan diseñar equipo, sistemas de distribución de energía, cadenas de suministro y otros procesos productivos de forma sustentable y brinden información sobre la factibilidad de invertir en este tipo de sistemas.

1.2.2 Objetivos Particulares

- Implementar estrategias de modelado para diferentes aplicaciones.
- Obtener diferentes escenarios para los parámetros inciertos utilizando valores aleatorios con diferentes distribuciones de probabilidad que representen adecuadamente el comportamiento de variables inciertas.
- Analizar diferentes casos de estudio donde se muestren las ventajas que tiene el utilizar los modelos de optimización.
- Comparar los resultados de los modelos desarrollados con los de modelos reportados en la literatura.

Capítulo 2

Marco teórico

2.1 Modelos de optimización

La optimización es una herramienta importante cuando se quiere analizar sistemas y tomar decisiones [16]. En términos matemáticos, un problema de optimización busca dar la mejor solución entre todas las soluciones factibles que se tienen bajo determinadas circunstancias. El primer paso para resolver un problema de optimización es el desarrollo de un modelo matemático adecuado. Es decir, se tienen que identificar tres elementos fundamentales. El primero es la función objetivo que se desea maximizar o minimizar, típicamente se buscan minimizar costos o maximizar ganancias. En segundo lugar, están las variables cuyos valores pueden ser manipulados con la finalidad de encontrar el valor óptimo de la función objetivo, en términos prácticos un flujo másico, una cantidad de productos vendidos o la capacidad de un equipo industrial son ejemplos de variables. Finalmente, el tercer elemento básico de un modelo de optimización son las restricciones. Estas últimas dan límites a los valores que las variables pueden tomar, por ejemplo, el flujo de una corriente de cualquier compuesto no puede ser negativo o la capacidad de un equipo no puede ser superior a la capacidad del equipo más grande disponible en el mercado. En la Fig. 2.1 se muestran las etapas principales en la formulación de un modelo matemático. En la fase de definición del problema se establecen los elementos más importantes del problema y se identifican las posibles

soluciones que pueda tener. También, se determina el nivel de detalle requerido y los potenciales usos que podrá tener. Posteriormente, en la fase de diseño, se especifica la información, las estrategias y algoritmos de programación matemática necesarios para desarrollar un modelo útil. Primero, se definen los parámetros de entrada y de salida y se delimita al sistema, además, se establecen las funciones matemáticas que se usarán en el modelo y se especifican las consideración y limitaciones que se hacen para poder tener un modelo que se pueda resolver usando el software y hardware disponibles. Finalmente, en la fase de evaluación se compara el modelo con los criterios que se establecen en la etapa de definición del problema, posteriormente, se hacen análisis de sensibilidad para corroborar que los resultados coincidan con el comportamiento real y lógico del sistema.

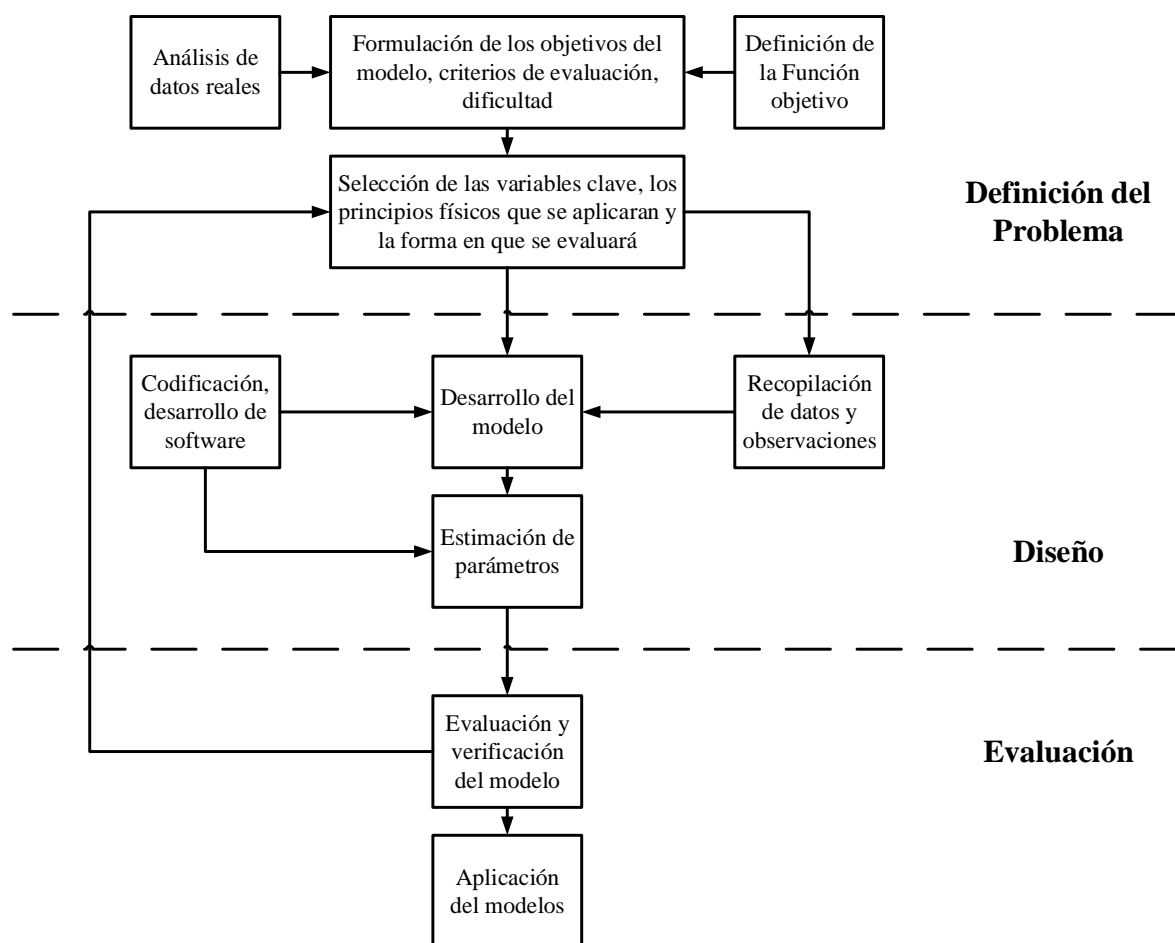


Figura 2.1: Actividades principales en la formulación de un modelo (tomado de Ref. [1]).

La validación del modelo requiere confirmar la lógica, las consideraciones y el comportamiento real. Lo cual se puede hacer comparando con datos históricos de los parámetros de entrada y de salida de sistemas existentes, con datos reportado en la literatura o con información de plantas piloto y/o simulaciones.

2.2 Clasificación de los problemas de optimización

Los problemas de optimización se pueden clasificar en las siguientes categorías dependiendo de la naturaleza de las variables de decisión, la función objetivo y las restricciones [16]:

- Programación Lineal (*LP, Linear Programming*): La función objetivo y las restricciones son lineales. Las variables de decisión son escalares y continuas.
- Programación No Lineal (*NLP, Nonlinear Programming*): La función objetivo y/o las restricciones son no lineales. Las variables de decisión son escalares y continuas.
- Programación Entera (*IP, Integer Programming*): Las variables de decisión son escalares y enteras.
- Programación Mixta Entera Lineal (*MILP, Mixed Integer Linear Programming*): La función objetivo y las restricciones son lineales. Las variables de decisión son escalares, algunas de ellas son enteras y otras continuas.
- Programación Mixta Entera No Lineal (*MINLP, Mixed Integer Nonlinear Programming*): Se refiere a un NLP que involucra al mismo tiempo variables de decisión continuas y enteras.
- Optimización Discreta (*Discrete Optimzation*): Son problemas que tienen variables de decisión discretas (enteras). Aquí se incluyen los IP, MILP y MINLP.
- Control óptimo (*Optimal Control*): Son problemas de optimización de sistemas que cambian con respecto del tiempo y generalmente implican la resolución de ecuaciones diferenciales.
- Programación Estocástica u Optimización Estocástica (*SP, Stochastic Programming or Stochastic Optimization*): También conocida como optimización bajo incertidumbre, su función objetivo y/o las restricciones incluyen variables inciertas (aleatorias). Usualmente se aplica en las categorías antes mencionadas como una subcategoría de cada una de ellas.

- Optimización Multiobjetivo (*Multiobjective Optimization*): Este apartado se refiere a los problemas que presentan más de una función objetivo y típicamente se incluye como subcategoría de las anteriores.

Como se mencionó anteriormente, la optimización incide y da solución a un gran número de problemas en ingeniería química y muchas otras áreas del conocimiento. Típicamente, estos problemas han sido representados por los modelos de optimización descritos anteriormente (LP, NLP, IP, MILP y MINLP); sin embargo, no siempre es posible saber con seguridad el comportamiento de algunos parámetros y/o variables del modelo determinista y la solución que brindan puede ser susceptible de escenarios no previstos anteriormente. En pocas palabras, estos modelos son incapaces de considerar más de una posibilidad. Cuando los modelos de optimización se utilizan para representar problemas reales es natural que se tenga una cantidad considerable de variables cuyo comportamiento no puede ser perfectamente preestablecido, ejemplo de ello son las condiciones climatológicas como la cantidad de precipitación, la velocidad del viento o la intensidad de la radiación solar. Cualquiera de estas variables pudiese pertenecer a un modelo de optimización para el diseño de determinado equipo. Si lo que se diseña es un sistema de captación de agua de lluvia y se utiliza un valor muy optimista de precipitación (llueve mucho) para el diseño, se tendría un equipo sumamente grande que la mayor parte del tiempo no operaría a su máxima capacidad y consecuentemente tendría un costo elevado, por otro lado, si el valor que se utiliza es pesimista (llueve poco) se tendría un equipo limitado en capacidad que no se aprovecharía adecuadamente. Obviamente, resulta imposible predecir el futuro perfectamente, pero es posible hacerle frente a esta incertidumbre utilizando la Optimización Estocástica. Hasta hace algunos años, los problemas que la optimización podía resolver se limitaban a problemas deterministas y era impensable resolver problemas estocásticos; no obstante, los avances que se tienen en la capacidad de cómputo permiten hoy en día realizar aproximaciones estocásticas que ofrecen mejores soluciones y proveen de más información a los tomadores de decisiones. A continuación, se describen los principales tipos de problemas de optimización, incluyendo a la optimización determinista y a la estocástica.

2.3 Optimización lineal

La optimización o programación lineal (LP) es una de las técnicas de optimización más usadas y efectivas. Esta técnica puede verse como parte de un gran desarrollo revolucionario, le ha dado a la humanidad la capacidad de seleccionar objetivos generales y establecer un camino detallado de toma de decisiones para lograr seleccionar la “mejor” opción cuando se enfrenta a situaciones prácticas de gran complejidad. Su origen se remonta a 1947 cuando George Dantzing desarrolló el método simplex y uso el termino *linear programming* por primera vez; además, su utilidad se mantiene vigente. Estos problemas de optimización tienen una función objetivo lineal y todas sus restricciones tienen relaciones lineales entre todas sus variables. La forma general de un LP es la siguiente:

$$\min c^T x \quad (2.1a)$$

$$s.t. Ax \leq b \quad (2.1b)$$

$$x \geq 0 \quad (2.1c)$$

Donde $A \in \mathbb{R}^{n \times m}$ y $n \leq m$.

Las variables de optimización son x ; la función objetivo es $c^T x$; A , b y c son los datos o parámetros; $Ax \leq b$ y $x \geq 0$ son las restricciones que especifican el politopo convexo sobre el cual se optimiza la función objetivo.

El ejemplo más popular de este tipo de problemas de optimización es el de la asignación de recursos, y en los últimos años se han reportado un gran número de aplicaciones en diferentes áreas de investigación como el análisis de la degradación de baterías en sistemas aislados integrados con energía solar [17], la optimización de la distribución y uso compartido de vehículos autónomos [18], la evaluación de la resiliencia energética en múltiples regiones [19], e incluso la optimización de una dieta de bajo costo para la prevención del cáncer [20]. Entre los *solvers* más conocidos para resolver este tipo de problemas se encuentran CPLEX, GUROBI y XPRESS.

2.4 Optimización no lineal

En un problema de optimización no lineal con restricciones se busca el mínimo (o máximo) valor de una función $f(x)$ con n variables reales $x = (x_1, x_2, \dots, x_n) \in X \subseteq \mathbb{R}^n$ sujetas a un conjunto de restricciones de igualdad $h(x) = 0$ ($h_i(x) = 0, i = 1, 2, \dots, m$) y de desigualdad $g(x) \leq 0$ ($g_j(x) \leq 0, j = 1, 2, \dots, p$) en donde alguna de las funciones $f(x)$, $h(x)$, y/o $g(x)$ es no lineal y se denota como [21]:

$$\min f(x) \tag{2.2a}$$

$$s.t. h(x) = 0 \tag{2.2b}$$

$$g(x) \leq 0 \tag{2.2c}$$

Este tipo de problemas abundan en problemas de ingeniería tales como el diseño, síntesis y control de procesos químicos y gracias a *solvers* como MINOS [22], CONOPT [23], KNITRO [24] e IPOPT [25], basados en algoritmos derivados del método de Newton como la programación cuadrática sucesiva [26]–[31], el gradiente reducido [32], [33] y el método del punto interior [34], es posible encontrar soluciones.

Las aplicaciones de la optimización no lineal va desde el ajuste de curvas por regresión no lineal, procesos de separación e intensificación de procesos [35], o la optimización de la cadena de suministro de una planta generadora de electricidad renovable [36]; hasta la planeación de la producción agrícola [37] o la predicción del consumo de energía eléctrica [38].

2.5 Optimización mixta entera lineal

Muchos problemas de operación, diseño, localización y planeación de procesos involucran variables que no son continuas, sino que tienen valores enteros. Por ejemplo, la decisión de seleccionar una tecnología u otra para realizar un proceso se puede representar en términos de variables binarias $\{0,1\}$. También, la potencia de un equipo puede estar determinada por

el mercado y las opciones podrían estar limitadas a 1hp, 2hp, 5hp y 10hp; sin embargo, un conjunto muy grande de variables enteras incrementa la dificultad del problema, en tal caso, puede llegar a ser preferible tratar a las variables enteras como variables continuas, aunque se obtengan soluciones subóptimas. Uno de los casos más comunes de problemas que involucran tanto variables continuas como variables enteras son los problemas de optimización mixtos enteros; sin embargo, existen problemas que involucran solamente variables enteras (problemas de programación entera). Muchos problemas mixtos enteros están compuestos por una función objetivo lineal y por restricciones lineales, a este tipo de problemas se les conoce como problemas de optimización mixtos enteros lineales (MILP). Los problemas MILP más comunes en ingeniería química involucran variables binarias y se denotan de la siguiente forma:

$$\min c^T x + d^T y \quad (2.3a)$$

$$s.t. Ax + By \leq b \quad (2.3b)$$

$$x \geq 0, \quad x \in X \subseteq \mathbb{R}^n \quad (2.3c)$$

$$y \in Y = \{0,1\}^q \quad (2.3d)$$

Donde x es un vector de n variables continuas; y es un vector de variables binarias (0 – 1) de dimensión q ; c , d son vectores de parámetros ($n \times 1$) y ($q \times 1$); A , B son matrices; b es un vector de p desigualdades. Para dar solución a este tipo de problemas, se han desarrollado diferentes métodos como el método de ramificación y acotamiento (*Branch and Bound*) [39], métodos de plano de corte (*Cutting plane methods*) [40] y métodos de descomposición [41] que han sentado las bases para el desarrollo de *solvers* como CPLEX, GUROBI, SCIP y XPRESS. Las aplicaciones que tiene la optimización mixta entera lineal son muy atractivas en área como la investigación de operaciones en donde se usa principalmente para resolver problemas de localización de infraestructura [42], planeación [43] y redes de transporte [44]. En lo que respecta a la ingeniería química clásica, se ha usado para la síntesis de procesos, integración energética, análisis de flexibilidad de procesos, planeación de procesos por lotes, etcétera. En años recientes, las metodologías usadas para

ingeniería química se han extendido e integrado con otras áreas de conocimiento con lo que se han desarrollado modelos MILP para la optimización del nexo agua-energía-alimentos en diferentes contextos y escalas [45]–[49], la planeación óptima en la transición energética hacia diferentes combustibles renovables [4], [50], la optimización de redes de agua y/o servicios auxiliares en parques eco industriales [51]–[53], la planeación de la reforestación a gran escala [54], [55] y el acoplamiento de la optimización de procesos con la optimización simultánea de su cadena de suministro [56]–[58].

2.6 Optimización mixta entera no lineal

Muchas aplicaciones requieren el uso simultáneo de variables enteras y continuas en problemas de optimización no lineales, esta clase de problemas de optimización se conocen como problemas de optimización mixtos enteros no lineales (MINLP). Las variables enteras típicamente son usadas para seleccionar entre diferentes alternativas y las variables continuas se usan para modelar los balances de materia y energía y las interacciones de las unidades u operaciones que integran el sistema. Los problemas MINLP son difíciles de resolver desde un punto de vista teórico, algorítmico y computacional debido a que se conjunta el dominio de las variables enteras con el dominio de las variables continuas y se acoplan con sus respectivas no linealidades. Sin embargo, las aplicaciones que tiene este tipo de problemas son muy variadas y de suma utilidad. En general un problema MINLP se puede representar de la siguiente manera cuando se consideran únicamente variables binarias:

$$\min_{x,y} f(x,y) \tag{2.4a}$$

$$s.t. \ h(x,y) = 0 \tag{2.4b}$$

$$g(x,y) \leq 0 \tag{2.4c}$$

$$x \in X \subseteq \mathbb{R}^n \tag{2.4d}$$

$$y \in Y = \{0,1\}^q \tag{2.4e}$$

A pesar de las dificultades que implica encontrar la solución de problemas MINLP, se han hecho muchos avances significativos en este sentido y como resultado se han formulados varios algoritmos. Algunos de los algoritmos que se usan para encontrar la solución de este tipo de problemas son el método de ramificación y acotamiento (*Branch and Bound*) [59], el método de ramificación y poda (*Branch and Cut*) [60], la descomposición generalizada de Benders (*Generalized Benders Decomposition*) [61], la aproximación exterior (*Outer-Approximation*) [62]. Estos avances, traducidos en la formulación de *solvers* como SBB, Bonmin, DICOPT, BARON, SCIP y ANTIGONE, en combinación con la evolución del poder de cómputo han permitido resolver problemas sumamente complicados relacionados a la planeación y diseño de redes para el suministro de agua [63], gas [64] y electricidad [65], la selección y localización de sistemas de almacenamiento energético [66], [67], el diseño de sistemas de generación distribuida [68], la planeación agrícola [69], entre otros.

2.7 Optimización estocástica con recurso

La optimización estocástica, también llamada programación estocástica (SP) u optimización bajo incertidumbre, es la rama de la optimización que involucra parámetros aleatorios en el modelo por lo que se combinan conceptos de optimización con teoría de probabilidad y estadística. Aunque se considera que esta disciplina nació en 1955 con Dantzig [70], históricamente la optimización se ha limitado a resolver problemas no estocásticos (deterministas), como los presentados en secciones anteriores, esencialmente por la complejidad que los problemas estocásticos entrañan. Afrontar problemas reales sin simplificaciones sigue siendo imposible en muchos casos, pero los avances en capacidad de cómputo y el desarrollo de las técnicas de optimización, han permitido resolver problemas que hasta hace pocos años parecían fuera de alcance. En optimización determinista se asume que toda la información necesaria para la toma de decisiones está disponible, pero en la optimización estocástica se busca la solución en un escenario que depende del azar. Es decir, cuando se considera incertidumbre no se tiene toda la información a la mano y algunos de los parámetros se modelan como variables aleatorias [71]; consecuentemente, no se tiene un solo escenario a optimizar sino un conjunto de escenarios probables y considerar una aproximación estocástica puede mejorar enormemente la solución, lo que se traduce en

minimización de pérdidas, disminución de costos, beneficios ambientales, sistemas robustos, etcétera.

En la optimización estocástica de dos etapas estándar se divide a las variables de decisión en dos conjuntos diferentes, el primero es un conjunto de variables que se toman sin contar con toda la información de los eventos aleatorios conocido como variables de primera etapa (x) y el segundo es un conjunto de variables que se toman después de la ocurrencia de los eventos inciertos para realizar cambios en la operación para mejorar o corregir y se conocen como variables de segunda etapa (ξ) [72]. Este concepto se ha aplicado a problemas de optimización enteros, lineales y no lineales.

En optimización matemática se define un problema de optimización estocástica de dos etapas de la siguiente forma:

$$\min c^T x + \mathbb{E}_\xi Q(x, \xi) \quad (2.5a)$$

$$s.t. Ax = b \quad (2.5b)$$

$$x \geq 0, \quad (2.5c)$$

Donde $Q(x, \xi) = \min \{q^T y \mid Wy = h - Tx, y \geq 0\}$, ξ es el vector formado por los componentes de q^T , h^T y T ; \mathbb{E}_ξ es la esperanza matemática con respecto de ξ . Se asume que W está fija (recurso fijo).

Los problemas de optimización estocástica han tenido aplicación en muchas áreas como la planeación de la producción, asignación de itinerarios, localización de infraestructura, expansión de capacidad, producción de electricidad, gestión y control ambiental, manejo de agua, agricultura, telecomunicaciones, diseño y optimización de sistemas de procesamiento químico, finanzas, etcétera.

2.8 Optimización estocástica con restricciones probabilísticas

En este trabajo se estudiaron problemas no lineales con restricciones probabilísticas (CC-P):

$$\min_{d \in \mathcal{D}} \varphi(d) \quad (2.6a)$$

$$s.t. \mathbb{P}\left(f(d, \Xi) \geq \bar{f}\right) \geq 1 - \alpha \quad (2.6b)$$

Aquí, $d \in \mathbb{R}^n$ son las variables de decisión y la función objetivo $\varphi: \mathbb{R}^n \rightarrow \mathbb{R}$ es dos veces continuamente diferenciable. El conjunto $\mathcal{D} := \{d \mid g(d) \geq 0\}$ se asume compacto, no vacío y se compone de restricciones dos veces diferenciables $g: \mathbb{R}^n \rightarrow \mathbb{R}^m$. Se considera el espacio de probabilidad $(\Omega, \mathcal{F}, \mathbb{P})$. Asumimos que Ω es un espacio medible equipado con σ -álgebra \mathcal{F} de subconjuntos de Ω y que $\bar{\Xi}$ es un espacio lineal de funciones \mathcal{F} -medibles $\Xi: \Omega \rightarrow \mathbb{R}^d$ (variables aleatorias representando datos de entrada). Las funciones de medida de la probabilidad están dadas por $\mathbb{P}: \mathcal{F} \rightarrow [0, 1]$ y se usa $\xi \in \mathbb{R}^d$ para denotar la realización de un vector con datos inciertos Ξ . La función de restricción escalar $f: \mathbb{R}^n \times \bar{\Xi} \rightarrow \mathbb{R}$ se asume dos veces continuamente diferenciable y potencialmente no convexa, también, $\bar{f} \in \mathbb{R}$ es un valor límite. Se define la variable escalar aleatoria $Z := f(d, \Xi)$ con realizaciones $z \in \mathbb{R}$. Se supone que Ξ y $Z = f(d, \Xi)$ (para todo $d \in \mathcal{D}$) son variables aleatorias continuas. Esto garantiza la existencia de una función de densidad de probabilidad (PDF) $p_Z: \mathbb{R} \rightarrow [0, \infty)$ y de una función de distribución acumulativa (CDF) $F_Z: \mathbb{R} \rightarrow [0, 1]$ de Z satisfaciendo $\mathbb{P}(Z \in (-\infty, \bar{f}]) = \int_{-\infty}^{\bar{f}} p_Z(z) dz = F_Z(\bar{f})$.

El CC requiere que el evento $\{f(d, \Xi) \in (-\infty, \bar{f}]\}$ ocurra con una probabilidad de al menos $1 - \alpha$. Desde $\mathbb{P}(Z \leq \bar{f}) = F_Z(\bar{f})$. El CC también se puede escribir como:

$$F_{f(d, \Xi)}(\bar{f}) \geq 1 - \alpha \quad (2.7)$$

O equivalentemente, $1 - F_Z(\bar{f}) = \mathbb{P}(Z > \bar{f}) \leq \alpha$. Hay que recordar que el cuantil- $(1-\alpha)$ de Z se define como:

$$Q_Z(1-\alpha) \in \operatorname{argmin}_{t \in \mathbb{R}} \{F_Z(t) \geq 1-\alpha\} \quad (2.8)$$

En la literatura de programación estocástica, el cuantil también se conoce como el valor en riesgo (*value-at-risk*, VaR) el cual se define como $\operatorname{VaR}_{1-\alpha}(Z) := Q_Z(1-\alpha)$. La definición del cuantil revela que puede ser expresado como el universo del CDF, y así el CC puede ser escrito como $\bar{f} \geq F_Z^{-1}(1-\alpha) = Q_Z(1-\alpha)$ ó de la siguiente manera:

$$Q_{f(d,\Xi)}(1-\alpha) \leq \bar{f} \quad (2.9)$$

$$\text{ó} \quad \operatorname{VaR}_{1-\alpha}(f(d,\Xi)) \leq \bar{f}.$$

Otra observación importante es que $\mathbb{E}[1_{\mathcal{W}}(Z)] = \mathbb{P}(Z \in \mathcal{W})$ se mantiene, donde $1_{\mathcal{W}}: \mathbb{R} \rightarrow \{0,1\}$ denota la función del indicador del conjunto \mathcal{W} (i.e., $1_{\mathcal{W}}(Z) = 1$ si $Z \in \mathcal{W}$ y $1_{\mathcal{W}}(Z) = 0$ si $Z \notin \mathcal{W}$). Como resultado, el CC (3.1b) puede ser escrito como:

$$\mathbb{E}[1_{(-\infty, \bar{f}]}(f(d,\Xi))] \geq 1-\alpha, \quad (2.10)$$

O, equivalentemente, $\mathbb{E}[1_{(\bar{f}, \infty)}(f(d,\Xi))] \leq \alpha$.

Se define al conjunto factible del CC-P como $\mathcal{D}(\alpha) := \mathcal{D} \cap \mathcal{P}(\alpha)$, donde $\mathcal{P}(\alpha) := \{d \mid \mathbb{P}(f(d,\Xi) \leq \bar{f}) \geq 1-\alpha\}$ y se asume que $\mathcal{D}(\alpha)$ sea compacto y no vacío para todo $\alpha \in (0,1]$. Se denota una solución óptima y un valor objetivo de CC-P como $d^*(\alpha)$ y $\varphi^*(\alpha)$, respectivamente. Este trabajo se enfoca en problemas con una simple CC, pero los conceptos discutidos se pueden aplicar también a múltiples CCs de la forma $\mathbb{P}(f_i(d,\Xi) \leq \bar{f}_i) \geq 1-\alpha_i, i = 1, \dots, r$. Las formulaciones con restricciones de probabilidad conjunta son significativamente más complejas y se dejan como tema de trabajo futuro.

Una característica particular y desafiante de los CC es que no se pueden manejar directamente con *solvers* de optimización estándar. El CC puede ser reformulado en un NLP cuando el

cuantil de la función $Q_{f(d,\Xi)}(1-\alpha)$ se puede expresar de forma algebraica. Esta propiedad se ha aprovechado extensivamente en el caso especial en el que el mapeo $f(d,\Xi)$ es lineal en ambos argumentos y el vector de datos aleatorios Ξ es Gaussiano [73]. Bajo estas condiciones, la variable $f(d,\Xi)$ es Gaussiana para todo $d \in \mathcal{D}$ y su cuantil puede ser expresado como una suma ponderada de sus momentos (el valor esperado y la varianza). Se pueden tener soluciones exactas cuando el CDF de $f(d,\Xi)$ y sus derivadas pueden ser calculadas explícitamente [74]. Para configuraciones más generales es posible derivar reformulaciones exactas usando variables enteras como se propuso originalmente en [75]. Desafortunadamente, en el contexto de CC-P, formulaciones enteras conducirían a programas mixtos enteros no lineales a gran escala y no convexos (MINLPs).

Aproximaciones manejables pero conservadoras de los CC-P se pueden utilizar para evitar la necesidad de resolver MINLPs. Se puede obtener una aproximación conservadora sencilla usando una técnica basada en escenarios [76], [77]. En esta aproximación se resuelve un NLP estocástico que cumple $f(d,\Xi) \leq 0$ con una probabilidad de uno (para todos los escenarios). Tal aproximación lleva a NLP estructurados, que a su vez se pueden resolver usando *solvers* paralelos de punto interior [78]. Este tipo de formulaciones estructuradas se están volviendo paulatinamente atractivas a medida que las computadoras con múltiples núcleos se han vuelto accesibles. Lamentablemente, la aproximación basada en escenarios puede conducir a resultados sumamente conservadores y no ofrece un control directo en el nivel de probabilidad del CC porque las variables de optimización tienen que satisfacer el 100% de los escenarios. Otras alternativas conservadoras incluyen la técnica del valor condicional en el riesgo (*Conditional value-at-risk*, CVaR) y la aproximación de Bernstein que usan aproximaciones a la función indicadora [79]. Otros autores [80] proponen una aproximación de diferencia de funciones convexas y muestran que la aproximación puede ser equivalente al CC-P; sin embargo, esta aproximación requiere un algoritmo especial de solución que no garantiza que funcione en una configuración general no convexa de NLP. Otra aproximación interesante es la llamada aproximación de Cantelli-Chebychev. En esta aproximación, el CC es reemplazado por una restricción de varianza media de la forma $\mathbb{E}[f(x,\Xi)] + \sqrt{(1-\alpha)/\alpha} \sqrt{\mathbb{V}[f(x,\Xi)]} \leq \bar{f}$ [81]. Esta aproximación es computacionalmente manejable, pero puede resultar en soluciones substancialmente conservadoras.

En este trabajo también se analizan aproximaciones exactas para resolver CC-P. Se considera el caso especial en que el que se conoce (o se conoce aproximadamente) la forma algebraica del cuantil y se propone usar *momento matching* para calcular sus parámetros. Este procedimiento se puede aplicar a una amplia variedad de distribuciones de probabilidad que van más allá de la Gaussiana como las distribuciones uniformes, log-normal, valor extremo generalizado (Weibull, Frechet, Gumbel), Laplace, exponencial y logística. La razón es que los fenómenos aleatorios, comúnmente observados en ciencias e ingenierías, se pueden explicar usando resultados asintóticos como el teorema de limite central o el valor extremo (Fisher–Tippett) y/o porque se pueden utilizar transformaciones básicas y relaciones fundamentales entre las diferentes distribuciones. A pesar de que esta aproximación no puede ser aplicada a la configuración general, se piensa que es importante estudiar la estructura del problema que se presenta para explorar si emergen aproximaciones algebraicas adecuadas. Para atender casos más generales, se considera el uso de la técnica de aproximación sigmoideal propuesta recientemente, la cual provee un mecanismo para encontrar soluciones de CC-P. Se demuestra que esta aproximación brinda mecanismos para encontrar una solución exacta para CC-P. También, se demuestra que esta aproximación supera significativamente el desempeño de aproximaciones conservadoras como CVaR y la basada en escenarios.

2.8.1 Estimación de momentos

Una complicación fundamental que implica utilizar CCs es que la forma del PDF de Z es una función compleja de la variable de decisión d y del modelo matemático $f(d, \Xi)$. Consecuentemente, es difícil generalmente anticipar la forma del PDF (y al mismo tiempo su CDF y la función del cuartil. Sin embargo, en algunos casos se puede anticipar la forma del PFD analizando como se propaga la incertidumbre de Ξ a través del modelo y explorando propiedades fundamentales de variables aleatorias y resultados estadísticos asintóticos. Lamentablemente, incluso si se conoce la forma del PDF, sus parámetros (es decir, posición, escala y forma) son también funciones complejas de las variables de decisión del modelo y por tanto no puede ser recalculada. La observación clave que se hace es que tales parámetros pueden ser calculados, sobre la marcha, usando técnicas de estimación de momentos (*moment matching*, MM).

El primer y segundo momento de la variable aleatoria Z son el valor esperado $\mathbb{E}[Z]$ y la varianza $\mathbb{V}[Z]$, respectivamente. Estos momentos muchas veces pueden ser expresados como funciones algebraicas de los parámetros del PDF de Z y así los parámetros del PDF se pueden inferir de observaciones empíricas de los momentos. Es decir, una aproximación estándar utilizada para ajustar las PDFs a datos empíricos.

Para la variable Gaussiana $Z \sim \mathcal{N}(a, b)$ con posición a y parámetro de escala b se tiene que $\mathbb{E}[Z]=a$ y $\mathbb{V}[Z]=b^2$. Como se discutió previamente, se puede garantizar que $Z = f(x, \Xi)$ es Gaussiana si el mapeo de restricciones es lineal y el vector aleatorio de entrada Ξ es Gaussiano. Por lo tanto, se tiene que la transformación lineal $m_1 + m_2 Z$ satisface $m_1 + m_2 Z \sim \mathcal{N}(m_1 + am_2, bm_2)$. Consecuentemente, si se tienen datos empíricos (observaciones) sobre la expectativa y la varianza de Z , entonces se pueden inferir los parámetros a, b . Para mostrar cómo se puede aplicar el MM para reformular CCs, se recuerda que el cuartil de la variable Gaussiana es $Q_Z(1-\alpha) = a + b\Phi^{-1}(1-\alpha)$, donde $\Phi^{-1}(1-\alpha)$ es el cuantil $1-\alpha$ de la variable Gaussian estándar (la cual puede ser precalculada). Consecuentemente, los CC-P pueden ser reformulados de la siguiente forma:

$$\min_{d \in \mathcal{D}, a, b} \varphi(d) \quad (2.11a)$$

$$\text{s.t. } \mathbb{E}[f(d, \Xi)] = a \quad (2.11b)$$

$$\mathbb{V}[f(d, \Xi)] = b^2 \quad (2.11c)$$

$$a + b\Phi^{-1}(1-\alpha) \leq \bar{f}, \quad (2.11d)$$

a, b son variables de decisión del problema porque los momentos son función de las variables de decisión d . Los datos empíricos para la expectativa y la varianza se pueden obtener usando un muestreo Monte Carlo (esta aproximación se conoce como una aproximación de muestra promedio o SAA). Lo anterior resulta en el siguiente NLP:

$$\min_{d \in \mathcal{D}, a, b} \varphi(d) \quad (2.12a)$$

$$\text{s.t. } \frac{1}{|\Omega|} \sum_{\xi \in \Omega} f(d, \xi) = a \quad (2.12b)$$

$$\frac{1}{|\Omega| - 1} \sum_{\xi \in \Omega} (f(d, \xi) - a)^2 = b^2 \quad (2.12c)$$

$$a + b\Phi^{-1}(1 - \alpha) \leq \bar{f}, \quad (2.12d)$$

donde $\xi \in \Omega$ son muestras independientes de Ξ . Es importante destacar que la reformulación (Ec. 2.31a) es una formulación media-varianza (ponderada por el cuantil $\Phi^{-1}(1 - \alpha)$). Esta formulación se asemeja a la aproximación de Cantelli-Chebyshev (ponderada por el factor $\sqrt{(1 - \alpha) / \alpha}$). Es posible apreciar que las formulaciones media-varianza provee una aproximación flexible para satisfacer el CC, pero es necesario ser cuidadoso al seleccionar una ponderación adecuada cuando la distribución de $f(x, \Xi)$ no es conocida para evitar violar el CC. El peso de la aproximación de Cantelli-Chebyshev garantiza que la aproximación siempre satisface la CC.

Para una variable aleatoria uniforme $Z \sim \mathcal{U}(a, b)$ se tiene que $\mathbb{E}[Z] = \frac{1}{2}(a + b)$ y

$\mathbb{V}[Z] = \frac{1}{12}(b - a)^2$, así, teniendo datos de la expectativa y la varianza de Z , se puede resolver

un sistema de dos ecuaciones para determina los parámetros a y b . Las transformaciones lineales de variables aleatorias uniformes también son uniformes. La función del cuantil para una variable aleatoria uniforme es $Q_Z(1 - \alpha) = a + (1 - \alpha)(b - a)$ para $\alpha \in (0, 1)$. La CC se puede reformular usando el siguiente conjunto de restricciones:

$$\mathbb{E}[f(d, \Xi)] = \frac{1}{2}(a + b) \quad (2.13a)$$

$$\mathbb{V}[f(d, \Xi)] = \frac{1}{12}(b - a)^2 \quad (2.13b)$$

$$a + (1 - \alpha)(b - a) \leq \bar{f}, \quad (2.13c)$$

Las variables aleatorias Gaussianas son de gran interés práctico debido a que muchos fenómenos aleatorios observados en aplicaciones de ciencia e ingeniería siguen este comportamiento. Esto también es, en parte, el resultado de uno de los resultados más fundamentales en estadística conocido como teorema de límite central, el cual señala que la suma de n idénticamente distribuida y la variable aleatoria independiente (de cualquier forma) $S_n = \frac{1}{n}(Z_1 + Z_2 + \dots + Z_n)$ es una variable Gaussiana cuando $n \rightarrow \infty$:

$$\lim_{n \rightarrow \infty} S_n \sim \mathcal{N}(a, b/\sqrt{n}). \quad (2.14)$$

Un resultado análogo y a menudo pasado por alto en estadística, conocido como el teorema de valores extremos (teorema de Fisher-Tippett), expone que el máximo de variables independiente y aleatorias idénticamente distribuidas (de cualquier forma) $M_n = \max\{Z_1, Z_2, \dots, Z_n\}$ siguen una distribución generalizada del valor extremo (*generalized extreme value*, GEV) cuando $n \rightarrow \infty$:

$$\lim_{n \rightarrow \infty} M_n \sim \text{GEV}(a, b, c). \quad (2.15)$$

La función del cuantil de la distribución GEV es:

$$Q_Z(1-\alpha) = \begin{cases} a - b \left(1 + \log(1-\alpha)^{-c}\right) / c & c < 0 \text{ or } c > 0 \\ a - b \log(-\log(1-\alpha)) & c = 0 \end{cases} \quad (2.16)$$

Aquí a, b, c son los parámetros posición, escala y forma de la distribución. Una variable aleatoria que sigue una distribución GEV usualmente se denota como $Z \sim \text{GEV}(a, b, c)$. El parámetro de forma c define diferentes tipos de distribución. En particular, cuando $c = 0$ la distribución GEV se transforma en una distribución Gumbel y el CC se puede reformular usando las siguientes restricciones:

$$\mathbb{E}[f(d, \Xi)] = a + \gamma b \quad (2.17a)$$

$$\mathbb{V}[f(d, \Xi)] = \frac{\pi^2}{6} b^2 \quad (2.17b)$$

$$a - b \log(-\log(1 - \alpha)) \leq \bar{f}, \quad (2.17c)$$

Donde x, a, b son variables de decisión. Curiosamente, las transformaciones lineales de variables aleatorias Gumbel son también Gumbel (es decir, si $Z \sim \text{GEV}(a, b, 0)$ entonces $m_1 + m_2 Z \sim \text{GEV}(m_1 + a m_2, b m_2, 0)$). Las variables GEV muchas veces son usadas para capturar eventos extremos y poco frecuentes como inundaciones y terremotos. Esta observación es importante porque el diseño de muchos sistemas de ingeniería, como la infraestructura, está sujeto a distribuciones de eventos extremos. En el contexto de los NLPs con CCs, las variables GEV han sido utilizada para diseñar sistemas de control para turbinas de viento, porque los eventos de tensión mecánica extrema limitan la región de actuación del controlador [82]. En particular, se observa que las cargas mecánicas extremas (pico) observadas en los horizontes de tiempo siguen una distribución de Gumbel (como sugiere el teorema de valores extremos) [83].

Existen muchas relaciones entre las PDFs y transformaciones funcionales que pueden ser aprovechadas para inferir la forma estructural de la densidad de $f(d, \Xi)$. Las transformaciones logarítmicas a menudo se encuentran en modelos físicos, además, es de particular interés la transformación de variables aleatorias Gaussianas (normales) a log-normal. Esto se hace al darse cuenta de que si $\log(Z) \sim \mathcal{N}(a, b)$ entonces Z es log-normal (representado como $Z \sim \text{LogN}(a, b)$). Otra forma de expresar esto es, si $Z \sim \mathcal{N}(a, b)$, entonces $\exp(X) \sim \text{LogN}(a, b)$. La función del cuantil de una variable log-normal es:

$$Q_Z(1 - \alpha) = \exp\left(a + b\Phi^{-1}(1 - \alpha)\right). \quad (2.18)$$

La distribución log-normal se usa para modelar variables que están sesgadas y que pueden tomar solamente valores positivos (por ejemplo, flujos, concentraciones). Las variables log-normal también tienen propiedades de transformación interesantes; por ejemplo, el producto

de variables log-normal resulta en una variable log-normal, las potencias de una variable log-normal son log-normal y la inversa de una variable log-normal también es una variable log-normal. También, es conocido que la suma de variables aleatorias Gumbel sigue una distribución logística. El cuantil de una distribución logística es:

$$Q_Z(1-\alpha) = a + b \log\left(\frac{1-\alpha}{\alpha}\right) \quad (2.19)$$

Mientras que los momentos de esta distribución son $\mathbb{E}[Z] = a$ y $\mathbb{V}[Z] = b^2 \pi^2 / 3$. Las transformaciones lineales también preservan la estructura de las variables aleatorias con distribución logística. Además, una transformación exponencial de una variable aleatoria logística $\exp(Z)$ sigue una distribución log-logística (un análogo de las variables normales y log-normal), la cual tiene un cuantil de la forma:

$$Q_Z(1-\alpha) = a \left(\frac{1-\alpha}{\alpha}\right)^{1/b} \quad (2.20)$$

Y los momentos son funciones algebraicas de a y b . Es sabido que si Z sigue una distribución exponencial (representada como $Z \sim \text{Exp}(a)$), entonces $\log Z$ tiene una distribución de Gumbel. El cuantil de una distribución exponencial esta dado por:

$$Q_Z(1-\alpha) = -\frac{1}{a} \log(\alpha), \quad (2.21)$$

Y el primer momento es $\mathbb{E}[Z] = 1/a$.

La distribución de Weibull es otro caso especial de la distribución GEV, la cual se obtiene para $c < 0$. Esta distribución se usa para modelar variables aleatorias no negativas y comúnmente surge en el análisis de confiabilidad. El cuantil de una distribución de Weibull tiene la forma algebraica:

$$Q_Z(1-\alpha) = a(-\log(\alpha))^{1/b} \quad (2.22)$$

Desafortunadamente, los momentos de una variable aleatoria de Weibull implican funciones gamma complejas de a, b y, por lo tanto, el *moment matching* es difícil de implementar computacionalmente. No obstante, la distribución de Weibull es de interés práctico porque a menudo surge de transformaciones de variables aleatorias. Por ejemplo, el logaritmo de una variable aleatoria uniforme produce una variable de Weibull y las potencias de una variable aleatoria exponencial son Weibull.

La distribución de Rayleigh es otra forma útil de representar variables aleatorias no negativas. Esta distribución tiene una función para el cuantil de la siguiente forma:

$$Q_Z(1-\alpha) = a\sqrt{-2\log(\alpha)}, \quad (2.23)$$

Y se nota que esta distribución solamente tiene un parámetro. Este parámetro se puede obtener haciendo coincidir el primer momento, el cual está dado por $\mathbb{E}[Z] = a\sqrt{\pi/2}$. Las variables aleatorias con distribución de Rayleigh tienen conexiones interesantes con otras variables aleatorias. Por ejemplo, si Z_1, Z_2 son variables independientes normales, entonces $Z = \sqrt{Z_1^2 + Z_2^2}$ es distribuido de la forma Rayleigh (denotado como $Z \sim \mathcal{R}(a)$). Esto indica que las variables Rayleigh son normas Euclidianas de vectores aleatorios con entradas independientes. También, es sabido que si Z sigue una distribución exponencial entonces \sqrt{Z} tiene una distribución Rayleigh y si Z es uniforme entonces $a\sqrt{-2\log Z}$ es Rayleigh.

En caso de necesitarlo, se puede encontrar un resumen de propiedades y transformaciones de variables aleatorias en Ref. [84].

En general es muy difícil inferir la estructura de la distribución de $Z = f(d, \Xi)$ debido a las complejas transformaciones no lineales llevadas a cabo en el modelo matemático y la presencia de restricciones de desigualdad. Cuando un análisis de estructura no es posible, posiblemente se recurra al análisis Monte Carlo para determinar la forma de $f(d, \Xi)$ a diferentes valores de x y verificar si la forma persiste y si esta sigue alguna distribución conocida. Desafortunadamente, este enfoque de exploración en general no es escalable. En consecuencia, para estas formulaciones más generales es necesario recurrir a técnicas de aproximación general, como se describe a continuación.

2.8.2 Aproximaciones para casos generales

Se abordaron aproximaciones para resolver CC-P de forma más general en los que no se conoce la forma de $f(d, \Xi)$.

Aproximación CVaR

Para facilitar el entendimiento de la nomenclatura, se redefine $Z \leftarrow Z - \bar{f}$ tal que la restricción del CC se convierte en $\mathcal{P}(Z \leq 0) \geq 1 - \alpha$, lo que es equivalente a $\mathcal{P}(Z > 0) \leq \alpha$.

Debido a que $\mathbb{P}(Z > 0) = \mathbb{E}[1_{(0, \infty)}(Z)]$, el CC se puede expresar como:

$$\mathbb{E}[1_{(0, \infty)}(f(d, \Xi) - \bar{f})] \leq \alpha. \quad (2.24)$$

Una técnica computacionalmente práctica para aproximar el CC es encontrar una aproximación conservadora. Esto se hace encontrando una función aproximada $\psi: \mathbb{R} \rightarrow \mathbb{R}$ que satisface $\psi(z) \geq 1_{[0, \infty)}(z) \geq 1_{(0, \infty)}(z)$ para cualquier $z \in \mathbb{R}$. Para tal función tenemos que $\psi(t^{-1}z) \geq 1_{[0, \infty)}(t^{-1}z) = 1_{(0, \infty)}(z)$ para cualquier parámetro $t > 0$. Por lo tanto:

$$\mathbb{E}[\psi(t^{-1}Z)] \geq \mathbb{P}(Z > 0). \quad (2.25)$$

Así se puede concluir que el cumplimiento de la restricción:

$$\mathbb{E}[\psi(t^{-1}Z)] \leq \alpha, \quad (2.26)$$

Implica que $\mathbb{P}(Z > 0) \leq \alpha$ se satisface (y también $\mathbb{P}(f(d, \Xi) \leq \bar{f}) \geq 1 - \alpha$). Debido a que la ecuación (3.21) es válida para todo $t > 0$ también se tiene que, si $\psi(\cdot)$ es convexo, entonces:

$$\inf_{t > 0} \{t \mathbb{E}[\psi(t^{-1}Z)] - t\alpha\} \leq 0 \quad (2.27)$$

Implica $\mathbb{P}(Z > 0) \leq \alpha$. La calidad de la aproximación conservadora depende de la selección de la función aproximada $\psi(\cdot)$. La selección de $\psi(z) := [1 + z]_+$ con $[z]_+ := \max\{z, 0\}$ conduce a la aproximación:

$$\inf_{t>0} \{ \mathbb{E}[[Z+t]_+] - t\alpha \} \leq 0. \quad (2.28)$$

Se muestra que $\inf_{t>0}$ puede ser remplazado con \inf_t para obtener:

$$\inf_{t \in \mathbb{R}} \{ \alpha^{-1} \mathbb{E}[[Z+t]_+] - t \} \leq 0 \quad (2.29)$$

redefiniendo $t \leftarrow -t$ y recordando que:

$$\text{CVaR}_{1-\alpha}(Z) := \inf_{t \in \mathbb{R}} \{ t + \alpha^{-1} \mathbb{E}[[Z-t]_+] \}, \quad (2.30)$$

Se puede observar que la ecuación (2.29) puede ser usada para derivar una aproximación conservadora de CC-P de la forma:

$$\min_{d \in \mathcal{D}} \varphi(d) \quad (2.31a)$$

$$\text{s.t. } \text{CVaR}_{1-\alpha}(f(d, \Xi) - \bar{f}) \leq 0. \quad (2.31b)$$

Se muestra un valor objetivo óptimo y una solución de este problema (indicado como CVaR-P) como $\varphi_c(\alpha)$ y $d_c(\alpha)$, respectivamente. Se define el conjunto factible del CVaR-P como $\mathcal{D}_c(\alpha)$ y se observa que debido a que CVaR provee una aproximación conservadora, que $\mathcal{D}_c(\alpha) \subseteq \mathcal{D}(\alpha)$. Como resultado, cualquier solución factible $d_c(\alpha)$ de CVaR-P es factible para CC-P. Esto también implica que $\varphi_c(\alpha) \geq \varphi(\alpha)$ para todo $\alpha \in (0, 1]$.

Se define $Z_c(\alpha) := f(d_c(\alpha), \Xi)$ y se recuerda que [85]:

$$\text{VaR}_{1-\alpha}(Z_c(\alpha)) = \operatorname{argmin}_t \{ t + \alpha^{-1} \mathbb{E}[[Z_c(t) - t]_+] \}, \quad (2.32)$$

Así, $\text{VaR}_{1-\alpha}(Z_c(\alpha)) \leq \text{CVaR}_{1-\alpha}(Z_c(\alpha))$. Esta observación también destaca que CVaR provee una aproximación conservadora para el CC. Se encontrará conveniente definir la constante:

$$\gamma_\alpha := -t_c(\alpha)^{-1}, \quad (2.33)$$

con $t_c(\alpha) \in \operatorname{argmin}_t \{t + \alpha^{-1} \mathbb{E}[Z_c(t) - t]_+\}$.

Una ventaja importante de la aproximación CVaR es que se puede resolver como un NLP estándar. Además, si $f(d, \xi)$ es convexo en d para ξ dado, CVaR también es convexo en d . Se puede probar que la función $\psi(z) = [1 + z]_+$ es la aproximación convexa más estricta de $1_{[0, \infty)}(z)$. A pesar de este beneficio, la aproximación CVaR puede ser bastante conservadora. Por otra parte, la aproximación CVaR no ofrece un mecanismo para forzar la convergencia a una solución para el CC-P.

Aproximación sigmoidea

Una observación importante es que la función indicadora puede ser aproximada por el exterior usando una función sigmoidea de la forma:

$$\psi_s^{\mu, \tau}(z) := \frac{1 + \mu}{\mu + e^{-\tau z}}, \quad (2.34)$$

donde $\mu, \tau \in \mathbb{R}_+$ son parámetros. Esta función sigmoidea es un caso especial de la función logística generalizada. La cual es una aproximación suave (y diferenciable) de la función indicadora [86]. La restricción CC asociada toma la forma:

$$\mathbb{E}[\psi_s^{\mu, \tau}(f(d, \Xi))] \leq \alpha \quad (2.35)$$

En este trabajo se considera una variante personalizada de la función sigmoidea anterior de la siguiente forma:

$$\psi_{ss}^{\mu, \tau}(z) := \left[2 \frac{1 + \mu}{\mu + e^{-\tau z}} - 1 \right]_+ \quad (2.36)$$

Esta se aproxima a la restricción probabilística CC:

$$\mathbb{E}[\psi_{ss}^{\mu, \tau}(f(d, \Xi))] \leq \alpha. \quad (2.37)$$

La motivación detrás de las variantes personalizadas esta ilustrada en la Fig. 3.1, donde se muestra que la variante es más precisa que su contraparte estándar. Esto es porque los conjuntos de la función máxima $\psi_{ss}^{\mu,\tau}(z) = 0$ para toda $z \leq -\delta$ y {donde $\delta := \frac{1}{\tau} \log(2 + \mu)$ }. En la Ref. [87] se muestra que las funciones sigmoideas brindan aproximaciones conservadoras para los CC para cualquier $\mu, \tau \in \mathbb{R}_+$, $\alpha \in (0,1]$, y $d \in \mathcal{D}$.




Figura 2.2: Aproximación conservadora de la función indicadora usando funciones sigmoideas (tomada de Ref. [87]).

Se utiliza la función sigmoidea personalizada para definir el *Sigmoidal Value-at-Risk* (SigVaR):

$$\text{SigVaR}_{1-\alpha}^{\mu,\tau}(Z) := \inf_{t \in \mathbb{R}} \left\{ \mathbb{E} \left[\psi_{ss}^{\mu,\tau}(Z-t) \right] \leq \alpha \right\} = \inf_{t \in \mathbb{R}} \left\{ \mathbb{E} \left[\left[2 \frac{1+\mu}{\mu + e^{-\tau(Z-t)}} - 1 \right]_+ \right] \leq \alpha \right\} \quad (2.38)$$

Y también se usa para formula la aproximación del CC-P:

$$\min_{d \in \mathcal{D}} \varphi(d) \quad (2.39a)$$

s.t.

$$\text{SigVaR}_{1-\alpha}^{\mu,\tau}(f(d, \Xi)) \leq \bar{f} \quad (2.39b)$$

Se define un objetivo óptimo y una solución de la Ec. (2.39) como $\varphi_{ss}^{\mu,\tau}(\alpha)$ y $x_{ss}^{\mu,\tau}(\alpha)$, respectivamente. También se define el conjunto factible de la Ec. (2.39) como $\mathcal{D}_{ss}^{\mu,\tau}(\alpha)$. Debido a que la función sigmoidea es una aproximación conservadora, se tiene que $\mathcal{D}_{ss}^{\mu,\tau}(\alpha) \subseteq \mathcal{D}(\alpha)$ para todo $\mu, \tau \in \mathbb{R}_+$. Esto implica que $\varphi_{ss}^{\mu,\tau}(\alpha) \geq \varphi(\alpha)$ para toda $\alpha \in (0,1]$ y $\mu, \tau \in \mathbb{R}_+$.

La definición de SigVaR está motivada por la observación de que $\text{VaR}_{1-\alpha}(Z) = \text{argmin}_{t \in \mathbb{R}} \{\mathbb{P}(Z-t > 0) \leq \alpha\}$ también puede ser expresada en términos de la función indicadora:

$$\text{VaR}_{1-\alpha}(Z) = \text{argmin}_{t \in \mathbb{R}} \{\mathbb{E}[1_{(0,\infty)}(Z-t)] \leq \alpha\} \quad (2.40)$$

Debido a que la función sigmoidea $\psi_{ss}^{\mu,\tau}(\cdot)$ es una aproximación conservadora de $1_{(0,\infty)}(\cdot)$, se tiene que:

$$\text{SigVaR}_{1-\alpha}^{\mu,\tau}(Z) \geq \text{VaR}_{1-\alpha}(Z) \quad (2.41)$$

Para todo $\alpha \in (0,1]$ y $\mu, \tau \in \mathbb{R}_+$. Consecuentemente, el SigVaR puede ser interpretado como un cuantil aproximado y Ec. (2.39) es una representación conservadora de los CC-P. Como en el caso de la representación del VaR del CC-P, el problema Ec. (2.39) no es particularmente atractivo para la computación. Sin embargo, este problema también tiene la siguiente forma equivalente (indicada como SigVaR-P):

$$\min_{d \in \mathcal{D}} \varphi(d) \quad (2.42a)$$

$$\text{s.t. } \mathbb{E}[\psi_{ss}^{\mu,\tau}(f(d, \Xi) - \bar{f})] \leq \alpha \quad (2.42b)$$

El problema SigVaR-P presenta propiedades interesantes, establecidas en la Ref. [87]. Las cuales indican que el SigVaR puede ser utilizado para resolver NLP de gran escala con restricciones probabilísticas mediante el uso de potentes *solvers* como Ipopt [25] y PIPS-NLP [88]. Esto se ha demostrado recientemente en el contexto del control de las turbinas de

viento, donde se demuestra que problemas con millones de variables pueden ser resueltos [82], [87].

Aproximación con probabilidad de 1 (Almost-Surely Aproximation, ASA)

Un enfoque directo para obtener una aproximación conservadora de CC es hacer cumplir la restricción $\mathbb{P}(f(d, \Xi) \leq \bar{f}) \geq 1 - \alpha$ con $1 - \alpha = 1$ (con una probabilidad de uno, es decir prácticamente seguro). Esto es equivalente a hacer que la restricción $f(x, \Xi) \leq \bar{f}$ se cumpla para todos los posibles escenarios de Ξ . La aproximación AS está dada por la formulación de programación estocástica estándar que está basada en escenarios como se muestra a continuación:

$$\min_{d \in D} \varphi(d) \tag{2.43a}$$

$$\text{s.t.} \quad f(d, \xi) \leq \bar{f}, \quad \xi \in \Omega \tag{2.43b}$$

Esta aproximación es popular debido a que es fácil de implementar y se puede resolver usando *solvers* NLP seriales y paralelos existentes.

2.9 Optimización Multiobjetivo

La optimización multiobjetivo engloba la solución de problemas de optimización con dos o más funciones objetivo. De manera general un problema de optimización multiobjetivo se formula matemáticamente de la siguiente manera:

$$\min \{f_1(x, y), f_2(x, y), \dots, f_{nf}(x, y)\} \tag{2.44a}$$

Sujeto a:

$$h(x, y) = 0 \tag{2.44b}$$

$$g(x, y) \leq 0 \tag{2.44c}$$

$$x \in \mathbb{R}^n, y \in \mathbb{R}^m, h \in \mathbb{R}^p, g \in \mathbb{R}^r$$

Como se puede apreciar el problema tiene nf objetivos, n variables continuas (x) y m variables discretas (y) así como vectores con restricciones de igualdad y desigualdad ($h(x, y)$ y $g(x, y)$, respectivamente).

Existe una gran cantidad de métodos para dar solución a los problemas de optimización Multiobjetivo, la mayoría ellos transforman el problema original en uno o una serie de problemas con una sola función objetivo.

Los métodos para resolver este tipo de problemas generalmente se clasifican de acuerdo con el número de soluciones generadas y el papel que los tomadores de decisiones tienen a la hora participar en la solución del problema. Se clasifican en dos grupos: *generating methods* y *preference-based methods*. Los primeros generan una o varias soluciones Pareto sin tomar en cuenta la opinión de los tomadores de decisiones, ya que los tomadores de decisiones intervienen una vez que se generan las soluciones. Por otro lado, los métodos basados en preferencias tienen la participación de los tomadores de decisiones para encontrar la solución al problema. A continuación se describen brevemente algunos de los métodos usados en la optimización multiobjetivo [89], [90].

2.9.1 Método de la suma ponderada

Usualmente un problema multiobjetivo se resuelve combinando los múltiples objetivos en una función escalar de un objetivo. Este método se conoce generalmente como suma ponderada (*weighted-sum*) [91]. El método de la suma ponderada minimiza una sumatoria de objetivos ponderados positivamente, es decir:

$$\min \sum_{i=1}^n \gamma_i \cdot f_i(x) \quad (2.45a)$$

Sujeto a:

$$\sum_{i=1}^n \gamma_i = 1 \quad (2.45b)$$

$$\gamma_i > 0, i = 1, \dots, n \quad (2.45c)$$

$$x \in S$$

Así se tiene un nuevo problema de optimización con una sola función objetivo. En este método los tomadores de decisiones son los encargados de determinar el peso adecuado para cada objetivo.

2.9.2 Método ε -constraint

Este método fue propuesto por Chankong y Haimes en 1983 [92]. En este método los tomadores de decisiones seleccionan un objetivo para minimizarlo y el resto de los objetivos se restringen a valores objetivo dados. En términos matemáticos, si se selecciona a $f_j(x)$ como la función objetivo que se busca minimizar, se tendría el siguiente problema:

$$\min f_j(x) \quad (2.46a)$$

Sujeto a:

$$f_i(x) \leq \varepsilon_i, \forall i \in \{1, \dots, n\} \quad (2.46b)$$

$$x \in S$$

2.9.3 Método Goal Programming

Este método data de Charnes y col. (1955), y Charnes y Cooper (1961). Consiste en transformar el problema de optimización multiobjetivo en un problema con un solo objetivo, de forma general se tiene un problema de la siguiente forma:

$$\min \sum_{i \in F} w_i \{d_i^+ \vee d_i^- \vee d_i^+ + d_i^-\} \quad (2.47a)$$

Sujeto a:

$$f_i(x) + d_i^- - d_i^+ = \text{objetivo}_i, \forall i \in F \quad (2.47b)$$

$$d_i^-, d_i^+ \geq 0, \forall i \in F \quad (2.47c)$$

$$h(x) = 0 \quad (2.47d)$$

$$g(x) \leq 0 \quad (2.47e)$$

$$x \in \mathbb{R}^n, h \in \mathbb{R}^p, g \in \mathbb{R}^r$$

Dependiendo de cómo se quiera abordar el problema se pueden minimizar diferentes combinaciones de d_i^+ , d_i^- como se muestra en la Tabla 2.1.

Tabla 2.1: Diferentes combinaciones de las variables de holgura.

Caso	Valor	Combinación de variables a minimizar
El i -ésimo valor de la función objetivo debe ser mayor o igual que el valor objetivo i .	Positivo	d_i^+
El i -ésimo valor de la función objetivo debe ser menor o igual que el valor objetivo i .	Negativo	d_i^-
El i -ésimo valor de la función objetivo debe ser igual que el valor objetivo i .	Cero	$d_i^+ + d_i^-$

El método *Goal Programming* se basa en estar lo más cerca posible del mínimo de cada función objetivo permitiendo desviaciones positivas o negativas como se muestra en la Fig. 2.3.

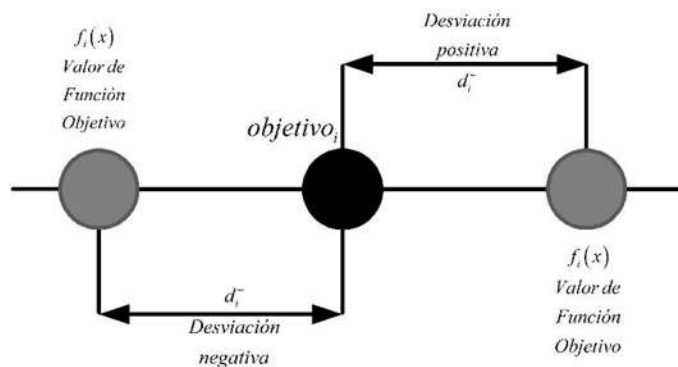


Figura 2.3: Desviaciones del objetivo.

Por otra parte, es importante normalizar los valores de las funciones objetivo y los valores objetivo:

$$f_i^{norm}(x) = \frac{f_i(x) - f_i^{min}}{f_i^{max} - f_i^{min}} \quad \forall i \in F \qquad \text{objetivo}_i^{norm} = \frac{\text{objetivo}_i - f_i^{min}}{f_i^{max} - f_i^{min}} \quad \forall i \in F$$

Donde f_i^{min} y f_i^{max} son los valores mínimo y máximo que puede alcanzar cada función objetivo.

Este método es el más utilizado en la optimización multiobjetivo y será utilizado en este trabajo.

Capítulo 3

Diseño de equipo, problemas NLP con restricciones probabilísticas

Las restricciones probabilísticas (en inglés, *chance constraints*, CC) son un poderoso paradigma de modelado matemático que ayuda a los tomadores de decisiones a controlar el riesgo. Desafortunadamente, las restricciones probabilísticas no pueden ser manejadas directamente por *solvers* de optimización convencionales y se necesitan reformulaciones y algoritmos especializados para encontrar una solución. En este capítulo, se estudian diferentes estrategias para abordar problemas de programación no lineales (NLP) con restricciones probabilísticas. En particular, se utiliza la estimación de momentos (*moment matching*) cuando se conoce la estructura algebraica de los momentos y la función cuantil de la distribución CC. Para abordar configuraciones más generales con distribuciones desconocidas, se utilizó una aproximación sigmoidea, que proporciona un mecanismo para lograr soluciones exactas. Se demostró que este enfoque reduce significativamente el conservadurismo de las aproximaciones populares, como el valor condicional en el riesgo (*conditional value-at-risk*) y el enfoque basado en escenario (asumiendo una probabilidad del 100%). Se utiliza un estudio sobre el diseño de un sistema de antorchas (*flares system*) para ilustrar las diferentes metodologías.

3.1 Diseño de antorchas (*Flare Systems*)

Se le denomina *Flaring* a la quema controlada de gases combustibles durante la producción o extracción de hidrocarburos y sus derivados. Un sistema para la quema controlada consta de una antorcha y un sistema de tuberías que recolecta los gases que serán quemados. La antorcha tiene una boquilla especialmente diseñada para mejorar la eficiencia de la combustión y cuenta con sellos que impiden el retroceso de la llama. Además, se tiene un sistema que remueve los líquidos que pudieran estar siendo arrastrados por las corrientes gaseosas. Estos sistemas normalmente generan una gran cantidad de ruido y calor, y normalmente producen principalmente vapor de agua y dióxido de carbono [93]. Sin embargo, la *Environmental Protection Agency* de Estados Unidos ha demostrado que las eficiencias de combustión de estos sistemas son mayores al 98%.

Los sistemas para la quema controlada de gases reciben corrientes de diversas composiciones que dependen del tipo de planta en donde se encuentren operando, pero usualmente son mezclas de hidrocarburos que pueden incluir desde hidrogeno hasta hidrocarburos pesados. Estas mezclas contienen vapores peligrosos o potencialmente tóxicos que se deben quemar completamente para prevenir daños al medio ambiente o a la salud humana.

Algunas de las razones principales por las que se lleva a cabo la quema y venteo de fluidos combustibles en los complejos petroleros son:

Seguridad en los procesos

- Quema continua de volúmenes pequeños irrecuperables.
- Manejo del exceso en la producción que la planta no puede manejar.

Problemas en la Operación

- Falla de un equipo.
- Productos fuera de especificación.
- Presiones más altas de las especificadas en algún equipo.
- Arranques de planta.
- Paros de emergencia.

Disposición final de gases.

- Quema de volúmenes pequeños cuya recuperación no es factible.
- Infraestructura suficiente.

Los sistemas que se utilizan para la disposición final de gases se conocen como antorchas. Las antorchas pueden utilizarse para controlar casi cualquier corriente de hidrocarburos y pueden manejar fluctuaciones en la concentración de mezclas combustibles gaseosas, razón de flujo, poder calorífico y contenido de inertes. La mayoría de las plantas de sustancias químicas y refinerías tienen sistemas actuales de antorcha diseñados para liberar perturbaciones en el proceso en casos de emergencia que requieren la emisión de grandes volúmenes de gas. Estas antorchas de gran diámetro diseñadas para manejar emisiones de emergencia; también pueden ser utilizadas para disponer corrientes de proceso que se encuentren fuera de especificación o cuando se sobreesa la capacidad de almacenamiento. Normalmente, los sistemas de antorchas para respuesta ante situaciones anormales son operados a un pequeño porcentaje de su capacidad y con presión despreciable.

Las antorchas son generalmente categorizadas de dos maneras: por la altura de la punta de la antorcha (en el suelo o elevada), y por el método de mejoramiento del mezclado en la boquilla de la antorcha (auxiliado con vapor, auxiliado con aire, auxiliado con presión o no auxiliado). Elevando la flama se pueden prevenir condiciones potencialmente peligrosas a nivel del suelo donde una flama al aire libre (una fuente de ignición), se localiza cerca de una unidad del proceso. Además, los productos de la combustión pueden dispersarse por encima de las áreas de trabajo para reducir los efectos del ruido, calor, humo y olores desagradables.

En la mayoría de las antorchas, la combustión ocurre por medio de una flama de difusión. Una flama de difusión es aquella en la que el aire se difunde a través de la interfase de las corrientes de combustible/productos de la combustión hacia el centro del flujo del combustible, formando la envolvente de una mezcla de gas combustible alrededor del núcleo de gas combustible. Esta mezcla, por la ignición, establece una zona de flama estable alrededor del núcleo de gas encima de la boquilla del quemador. Este núcleo interno de gas se calienta por difusión de los productos calientes de la combustión de la zona de la flama. Puede ocurrir desintegración con la formación de pequeñas partículas calientes de carbón que dan a la flama su luminosidad característica. Si hay una deficiencia de oxígeno y las partículas de carbón son enfriadas por debajo de su temperatura de ignición ocurre el tiznado. En las flamas de difusión grandes, se pueden formar vórtices de los productos de la combustión alrededor de partes del gas que se está quemando y apagar el suministro de oxígeno. Esta inestabilidad localizada causa que la flama vacile, lo que puede ser acompañado por la formación de hollín. Tal como en todos los procesos de combustión, se requiere un adecuado

suministro de aire y un buen mezclado para una combustión completa y minimizar el humo. Los varios diseños de antorcha difieren principalmente en su grado de mezclado. Los diferentes tipos de antorchas son: antorchas auxiliadas con vapor, antorchas auxiliadas con aire, antorchas no auxiliadas, antorchas auxiliadas con presión y antorchas cerradas a nivel de suelo.




Figura 3.1: Esquema general de una antorcha.

Se considera el diseño de antorchas para la quema de gases combustibles de desecho para comparar la efectividad de los métodos mencionados anteriormente para CC. Las antorchas se utilizan como dispositivos de seguridad para manejar situaciones anormales en plantas de extracción, procesamiento y transporte de combustibles fósiles como el petróleo y gas natural, plantas de manufactura de productos químicos e instalaciones para la generación de energía. Las situaciones anormales incluyen fallas en los equipos, productos fuera de especificación, exceso de productos, arranques de planta y paros de operación. La función de las antorchas es evitar un aumento de presión en el sistema y utiliza la combustión para convertir sustancias corrosivas, tóxicas y/o inflamables en compuestos menos peligrosos [94]. El diseño de estos equipos se ve influenciado por diferentes fuentes de incertidumbre. Por ejemplo, la cantidad y la composición del flujo que se alimenta para ser quemado cambian constantemente. Además, factores ambientales como la velocidad del viento también afectan el desempeño del equipo. Actualmente, este tipo de sistemas

se diseñan en base a datos históricos de las características de la corriente de alimentación y de las condiciones ambientales del lugar donde se pretende instalar el equipo [94], [95]. Consecuentemente, un mal diseño de antorchas puede hacer que el equipo sea vulnerable a escenarios extremos que no se presentan con regularidad. Se propone utilizar una formulación de programación estocástica para capturar las condiciones inciertas en el diseño.

3.1.1 Modelo Matemático

En esta sección se presenta el modelo matemático para diseñar antorchas. El objetivo que se tiene es minimizar el costo del equipo mientras se busca controlar el nivel de radiación térmica a nivel del suelo (la radiación que se tenga está en función de las características del flujo de entrada Q). El modelo se basó en la metodología del *American Petroleum Institute, standard 521* [95].

El calor emitido por la combustión H (BTU/h) está en función del flujo aleatorio de gas combustible de desecho Q (lb/h) y el calor de combustión h_c (BTU/lb):

$$H = h_c Q \quad (3.1)$$

La longitud de la flama L (ft) se puede calcular como una función del calor emitido usando la siguiente aproximación:

$$\log L = a_1 \log H - a_2 \quad (3.2)$$

El diámetro de la antorcha t (ft) se dimensiona basado en la velocidad a la que sale el gas. Es decir, relacionando el número de Mach, M y el flujo de salida.

$$M^2 = \left(\frac{a_3}{t^2} \right) Q^2 \quad (3.3)$$

La velocidad de salida en los quemadores de la antorcha es una función del flujo y el diámetro que se tienen:

$$U = a_4 \frac{Q}{t^2} \quad (3.4)$$

La velocidad del viento w (ft/s) es un factor ambiental muy importante ya que afecta la inclinación de flama de la antorcha y consecuentemente la distancia al centro de la flama. Las siguientes ecuaciones capturan el comportamiento de la distorsión de la flama en función de la velocidad salida y la velocidad del viento:

$$\log \Delta X = \log(a_5 L) + a_6 (\log w - \log U) \quad (3.5)$$

$$\log \Delta Y = \log(a_7 L) - a_8 (\log w - \log U) \quad (3.6)$$

ΔX y ΔY (ft) son las distorsiones horizontal y vertical, respectivamente. Estas distorsiones de la flama se utilizan para calcular las distancias horizontal X , vertical Y y la distancia total D (ft) entre la flama y el punto de seguridad a nivel de suelo $(r, 0)$:

$$X = r - \left(\frac{1}{2}\right) \Delta X \quad (3.7)$$

$$Y = h + \left(\frac{1}{2}\right) \Delta Y \quad (3.8)$$

$$D^2 = X^2 + Y^2 \quad (3.9)$$

Aquí, h (ft) es la altura de la antorcha como se ilustra en la Fig. 3.2.

La radiación térmica que emite la flama K (BTU/h ft²) es una función del calor liberado y la distancia total entre la flama y el punto de seguridad $(r, 0)$:

$$K = a_9 \left(\frac{H}{D^2}\right) \quad (3.10)$$

El objetivo primordial para que la antorcha funcione como un dispositivo de seguridad es diseñarla controlando el riesgo de la que radiación térmica exceda un determinado valor \bar{k} (BTU/h ft²) en el punto de seguridad $(r, 0)$. Esto se modela usando una restricción probabilística:

$$P(K \leq \bar{k}) \geq 1 - \alpha \quad (3.11)$$

La función objetivo es la ecuación para calcular el costo del equipo, el cual está en función de la altura y el diámetro de éste:

$$\varphi(t, h) = (a_{10} + a_{11}t + a_{12}h)^2 \quad (3.12)$$

La altura y el diámetro juegan un papel fundamental en el control de la radiación en el punto de seguridad, es decir, entre más alta sea y mayor diámetro tenga, la antorcha más baja será la intensidad de la radiación. Sin embargo, tener una antorcha innecesariamente alta tiene un costo económico muy elevado.

Algunas de las ecuaciones del modelo anterior se obtienen aplicando transformaciones logarítmicas a las ecuaciones físicas originales, mientras que algunas ecuaciones se han dejado en su forma original. En particular, el modelo busca resaltar cómo se propaga la incertidumbre en el flujo de gases combustibles de desecho Q a través del modelo, lo cual conduce a tener incertidumbre en la radiación resultante K , que define la restricción probabilística del problema.

3.1.2 Parámetros

Los parámetros a_1, \dots, a_{12} pueden obtenerse de parámetros físicos y económicos (por ejemplo, emisividad, peso molecular y temperatura). No se proporcionan las ecuaciones del modelo original ni las expresiones detalladas de los parámetros para simplificar la presentación. El lector interesado puede encontrar el modelo detallado (en su forma original) y los parámetros asociados en: <https://github.com/zavalab/JuliaBox/tree/master/FlareDesign>.

3.1.3 Resultados

El objetivo es diseñar una antorcha minimizando el costo y cumpliendo con la restricción de probabilidad para la radiación usando 4 métodos diferentes *Moment Matching* (MM), *Conditional Value At Risk* (CVaR), *Sigmoidal Approximation* (SigVaR) y *Almost Surely Approximation* (AS). En cada uno de los métodos se resolvieron 1000 escenarios generados aleatoriamente para el flujo de alimentación. Se exploraron dos casos diferentes en el primero la variable aleatoria del flujo de alimentación sigue una distribución Log-Normal (con una media $a = 10,000$ lb/h y una desviación estándar $b = 3,000$ lb/h) y en el segundo tiene una distribución exponencial (con un parámetro de distribución $a = 21,000$ lb/h). El diseño de la antorcha debe satisfacer la restricción de probabilidad

para la radiación con un valor máximo de $\bar{k} = 2,000$ BTU/h ft² y con una probabilidad $1 - \alpha = 0.95$. Todos los problemas formulados son no lineales y se resolvieron utilizando el lenguaje de modelación matemática JuMP [96] con el *solver* Ipopt [25].

La Tabla 1 y la Tabla 2 presentan el costo, diámetro y altura óptimos de la antorcha utilizando los métodos propuestos. Los resultados muestran que para ambas distribuciones el diámetro óptimo es el mismo para CVaR, SigVaR y MM. Esto se debe a que la constante asociada al costo en función del diámetro (a_{11}) es 12 veces mayor que la relacionada con la altura (a_{12}). Por lo tanto, es menos costoso incrementar la altura del dispositivo de seguridad que incrementar su diámetro para satisfacer la restricción de la radiación térmica.

Los resultados también muestran que el método AS presenta los diseños más conservadores. En el caso de la distribución log-normal, el diseño AS es 64% más caro que el diseño MM, en este mismo sentido, para el caso exponencial es 44% más costoso. Esto se debe a que el método AS no permite un control explícito en la probabilidad con la que se satisface la restricción de la radiación térmica. Por otro lado, el método CVaR reduce el sobredimensionamiento, pero sigue ofreciendo soluciones significativamente conservadoras. En el caso de la distribución log-normal, la altura óptima que resulta con CVaR es 67.70% mayor que la que se obtiene con MM y para la distribución exponencial es 49.76% mayor que la resultante de MM. Consecuentemente, el diseño CVaR es 20% más costoso en el caso log-normal y 17% mayor para el caso exponencial. Se puede concluir que CVaR ayuda a disminuir el sobredimensionamiento de los equipos que se tiene con AS sin la necesidad de conocer la PDF de la radiación; sin embargo, este método sigue ofreciendo soluciones conservadoras. Los resultados también muestran que las soluciones de SigVaR y MM son muy cercanas (el diseño de SigVaR es 1% más caro para el caso log-normal y 3% mayor para el caso exponencial).

Es importante recordar que el método MM provee los parámetros de la PDF de la radiación cuando encuentra una solución óptima. En el caso de la distribución exponencial se sabe que la tasa es el recíproco de la radiación promedio en la solución $\mathbb{E}[K] = 1/a$ (se obtiene una solución de $a = 0.0014978$). Para el caso log-normal se tiene que los parámetros de posición son la media del logaritmo de la radiación $\mathbb{E}[\log(K)] = a$ (en la solución se obtiene $a = 5.66$) y la desviación estándar $\mathbb{V}[\log(K)] = b^2$ (en la solución se obtiene $b = 1.178$).

Tabla 3.1: Valores óptimos de las variables de diseño cuando el flujo de alimentación sigue una distribución Log-Normal.

	AS	CVaR	SigVaR	MM
Costo (USD)	233,179	172,329	143,609	142,128
Diámetro (ft)	1.70	1.70	1.70	1.70
Altura (ft)	179.87	105.08	62.16	63.00

Tabla 3.2: Valores óptimos de las variables de diseño cuando el flujo de alimentación sigue una distribución Exponencial.

	AS	CVaR	SigVaR	MM
Costo (USD)	146,470	118,072	105,589	101,258
Diámetro (ft)	1.30	1.30	1.30	1.30
Altura (ft)	127.54	84.39	63.78	56.35

La Fig. 3.2 muestra las PDFs empíricas para el flujo de alimentación (asumiendo una distribución log-normal) y para la radiación de la solución óptima usando los métodos CVaR, SigVaR y MM. La distribución de la radiación que se obtiene con el MM también se compara contra el modelo de PDF correspondiente y se observa que la estructura del modelo conserva la distribución log-normal del flujo de alimentación. También, se observa que los histogramas de SigVaR y MM son muy similares, siendo SigVaR ligeramente más conservador. Esto se puede observar principalmente en las colas de la distribución, la cola de SigVaR alcanza valores de $6,000\text{Btu/hft}^2$ mientras que la de MM presenta valores de hasta $6,100\text{Btu/hft}^2$. Además, el histograma de CVaR muestra lo conservadora que es esta aproximación ya que apenas alcanza valores de $4,000\text{Btu/hft}^2$.

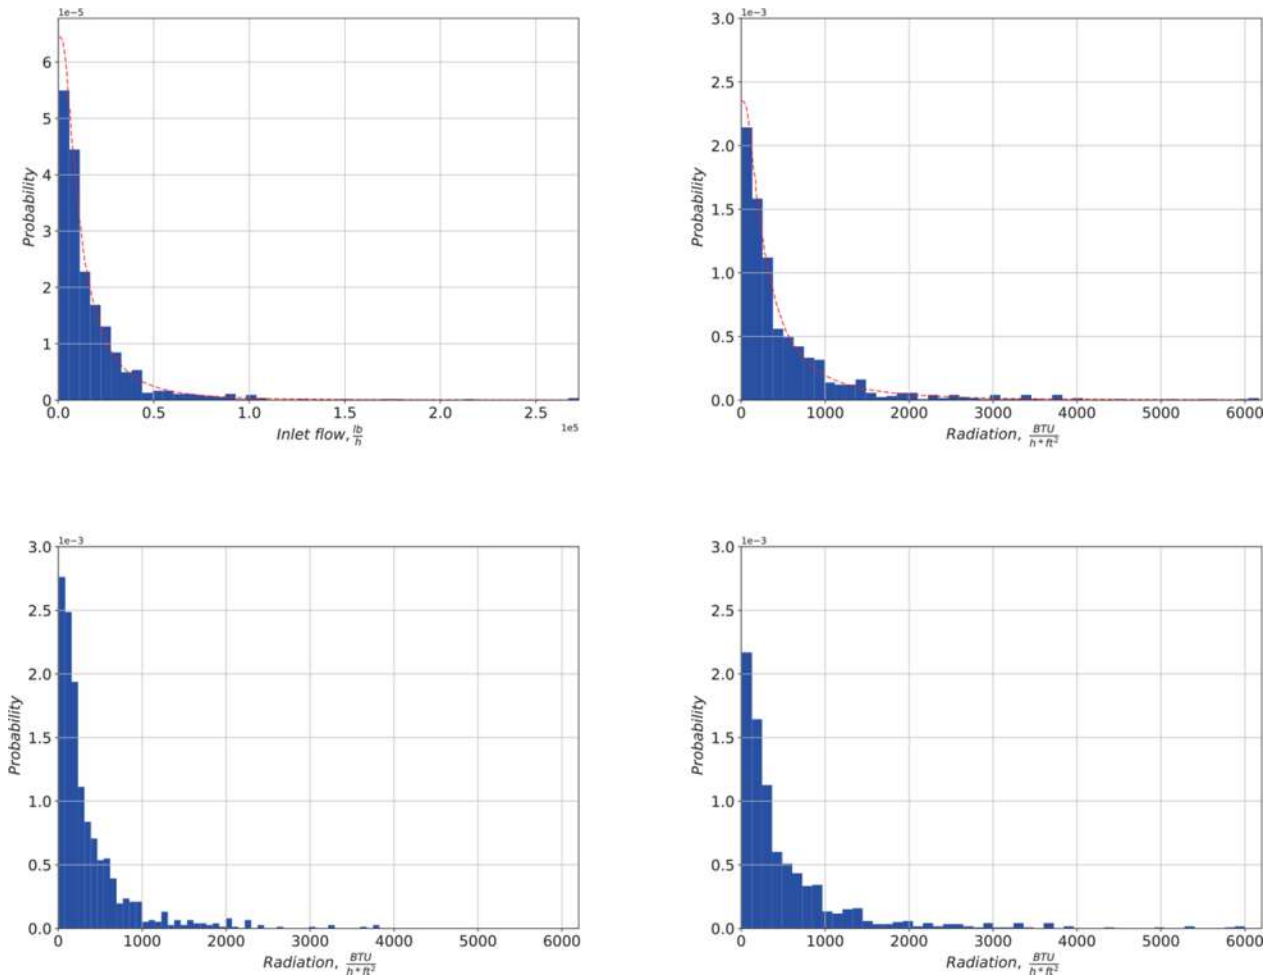


Figura 3.2: PDF del flujo de alimentación asumiendo distribución log-normal (arriba-izquierda); PDF de la radiación usando MM (arriba-derecha); PDF de la radiación usando CVaR (abajo-izquierda); PDF de la radiación usando SigVaR (abajo-derecha).

La Fig. 3.3 muestra la distribución empírica de la alimentación asumiendo una distribución exponencial y la distribución de la radiación de las soluciones óptimas de los métodos CVaR, SigVaR y MM. Para esta distribución se confirma que la estructura del modelo conserva la forma exponencial del flujo de alimentación. Para este caso, el comportamiento de la cola de la distribución SigVaR se desvía de forma más perceptible. Para el caso de SigVaR, la cola alcanza valores de hasta $3,900\text{Btu/hft}^2$ y para el MM de hasta $4,200\text{Btu/hft}^2$. De igual forma la solución de CVaR es la más conservadora ya que alcanza solo valores de $3,000\text{Btu/hft}^2$.

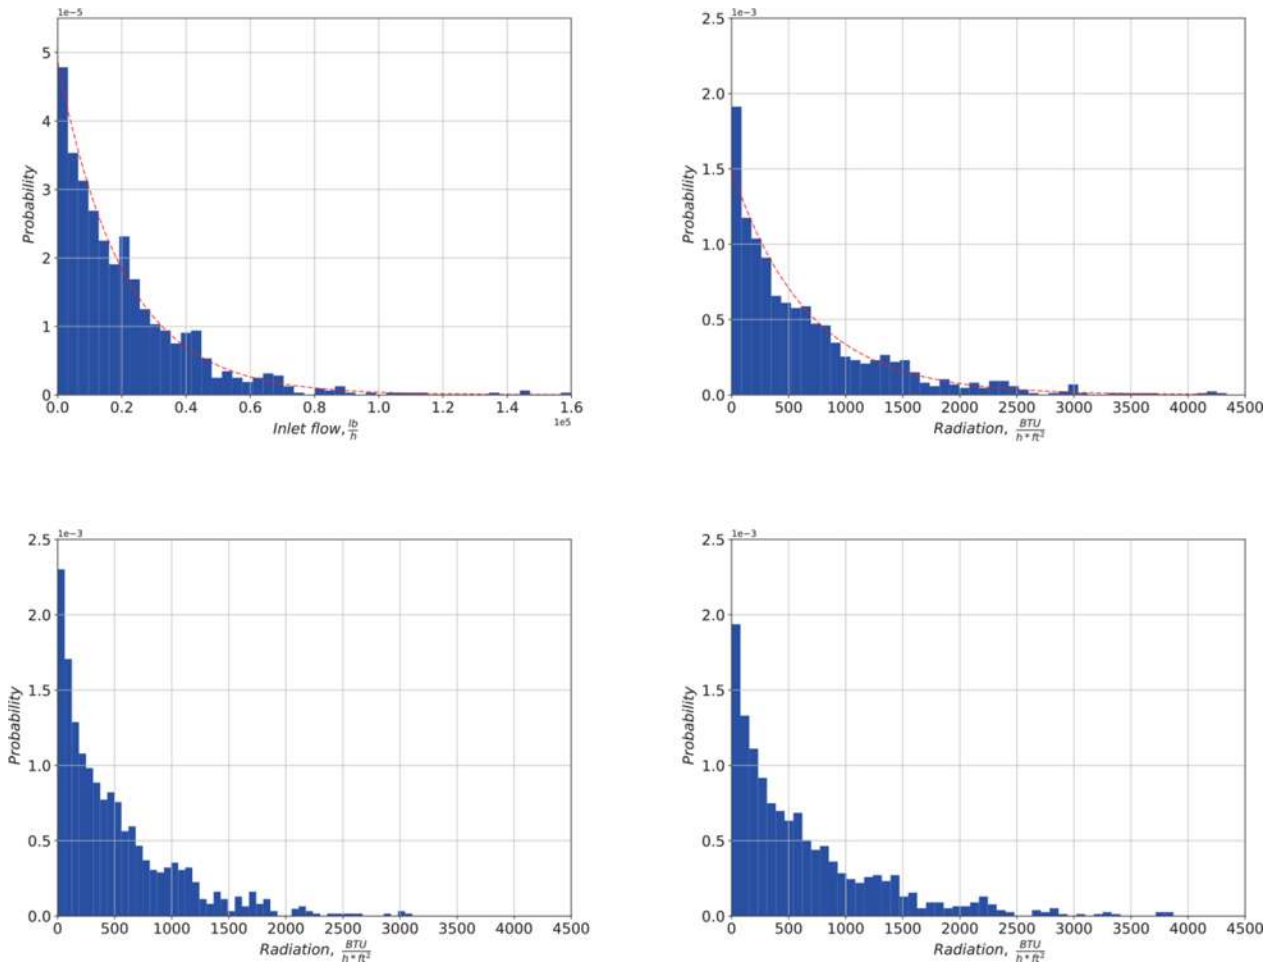


Figura 3.3: PDF del flujo de alimentación asumiendo distribución exponencial (arriba-izquierda); PDF de la radiación usando MM (arriba-derecha); PDF de la radiación usando CVaR (abajo-izquierda); PDF de la radiación usando SigVaR (abajo-derecha).

Adicionalmente, se obtiene la CDF empírica de la radiación para las soluciones de las aproximaciones CVaR y SigVaR para comparar los diferentes niveles de precisión de los diferentes métodos para hacer cumplir las restricciones probabilísticas. Esto también se hace para MM para verificar que la CDF sigue la forma predefinida y para corroborar si un error en la predefinición de la distribución no incurre en un error al satisfacer la restricción probabilística. La Fig. 3.4 compara la CDF log-normal contra la CDF empírica (obtenida con el MM). Las líneas rojas punteadas señalan el límite deseado con la respectiva probabilidad alcanzada en el mismo. Se puede observar que la CDF log-normal y la CDF empírica se traslapan y que la probabilidad $1 - \alpha$ es exactamente 95% para el límite deseado ($2,000 \text{ Btu/hft}^2$). Lo anterior indica que la CDF de la radiación es efectivamente log-normal cuando los valores del flujo de alimentación siguen una distribución log-

normal (Fig. 3.4, izquierda) y, de igual forma, exponencial cuando el flujo de alimentación tiene una distribución exponencial (Fig. 3.4, derecha). También se puede observar que el error de la CDF es ligeramente mayor para el caso exponencial lo que significa que el número finito de escenarios utilizados no es suficiente, pero esto no parece afectar la aplicación del CC de una manera perceptible.




Figura 3.4: CDF de la radiación cuando se asume una distribución log-normal (izquierda); CDF de la radiación cuando se asume una distribución exponencial. Resultados de MM (derecha).

La Fig. 3.5 compara las CDF de los métodos CVaR, SigVaR y MM. Se aprecia fácilmente que la curva correspondiente a CVaR es una solución bastante conservadora ya que la probabilidad de que la radiación este por debajo del valor deseado es 98% (se requería solamente 95%). También, se observa que las curvas para MM y SigVaR se superponen, lo cual indica que en este caso suponer la distribución resultante con MM es una buena aproximación y al mismo tiempo que SigVaR, a pesar de ser un método aproximado, provee una buena aproximación ya que logra satisfacer la restricción con la probabilidad deseada.




Figura 3.5: CDF para la radiación cuando el flujo de alimentación sigue una distribución Log-Normal (izquierda). CDF para la radiación cuando el flujo de alimentación sigue una distribución Exponencial (derecha).

Capítulo 4

Diseño de equipo y políticas de carbono, problemas NLP multiobjetivo

Este trabajo tiene como objetivo estudiar el efecto de la monetización de gases de efecto invernadero para promover la reducción de los gases combustibles de desecho (GCD) mejor conocidos como *flares*. Se propone diseñar un sistema de cogeneración que utilice gas natural como combustible principal y *flares* como combustible complementario. Se presenta un modelo de programación no lineal multiobjetivo para determinar las variables de diseño óptimas del sistema de cogeneración. Este modelo busca maximizar las ganancias y minimizar el dióxido de carbono equivalente simultáneamente. El factor clave para minimizar las emisiones de dióxido de carbono es el reemplazo de gas natural con GCD. Se comparan tres casos diferentes, que consideran diferentes métodos para fomentar el uso de GCD. El primer caso busca maximizar las ganancias con el comercio de emisiones de carbono. El segundo caso también busca maximizar la ganancia, sin embargo, las emisiones de dióxido de carbono están penalizadas por los impuestos de carbono. En el tercer caso, se presenta un enfoque de optimización multiobjetivo basado en una solución de compromiso que equilibra las prioridades en conflicto en múltiples objetivos. Los resultados muestran que los dos esquemas de políticas de carbono mencionados funcionan para disminuir las emisiones de dióxido de carbono, pero con algunas limitaciones. Por otro lado, cuando se

utiliza el enfoque basado en una solución de compromiso, los resultados muestran, al mismo tiempo, beneficios ambientales y económicos.

4.1 Análisis de precios de carbono en proyectos de mitigación de emisiones

Desde la firma del protocolo de Kioto han tenido lugar un gran número de acciones y acuerdos internacionales con la finalidad de tomar acciones para mitigar el cambio climático. Por ejemplo, el acuerdo de Paris tiene como objetivo mantener el incremento de la temperatura promedio global por debajo de 2°C a través de acciones que favorezcan la reducción de gases de efecto invernadero [97]. Además, muchos países han establecido estrategias claras y ambiciosas en este mismo sentido. No obstante, es importante señalar que existen países que son incapaces de seguir las estrategias para la mitigación del cambio climático porque la capacidad de sus economías no lo permiten [98]. Con la finalidad de apoyar el desarrollo de las energías renovables y de proyectos para la mitigación de gases de efecto invernadero se han establecido políticas ambientales a nivel internacional y local [99]. Estas políticas juegan un papel importante para garantizar la seguridad del suministro de energía, la protección del medio ambiente y para coordinar la producción de energía con el desarrollo económico y abordar el cambio climático global [100].

Los impuestos de carbono (*Carbon tax*) y el sistema de comercio de emisiones (*carbon emission trading*) son dos políticas regulatorias de emisiones que se practican a nivel internacional. El primero busca controlar la generación de emisiones aplicando penalizaciones económicas. Es decir, a los generadores antropogénicos de emisiones se les cobran impuestos en función de la cantidad de gases de efecto invernadero que liberan al medio ambiente [101]; por tanto, los precios de sus productos o servicios se incrementan y la demanda se puede ver potencialmente afectada. La ventaja de implementar un sistema de penalización económica ideal es que se alienta el uso de fuentes alternas de energía al darle un costo competitivo en un mercado lleno de combustibles más baratos y menos sustentables [102]. Por otro lado, en el comercio de emisiones se negocia el “derecho” a emitir gases de efecto invernadero. Entonces, los participantes con altos costos de reducción de emisiones pagan la remediación de sus emisiones y los participantes con bajos costos de reducción de emisiones son recompensados económicamente por invertir en tecnologías para mitigar emisiones [103]. La principal ventaja de implementar el comercio de emisiones es que se

asegura que los objetivos de reducción de emisiones se logran a un menor costo que el que se tendría si se forzara a cada generador de emisiones a disminuirlas. Otra ventaja es que se provee al sector privado con un sistema flexible que reduce emisiones mientras se estimula la innovación tecnológica y el crecimiento económico. Este mecanismo provee apoyo económico a proyectos de reducción de emisiones de gases de efecto invernadero; sin embargo, el efecto en diferentes regiones o sectores económicos puede variar si se utiliza el mismo sistema [104]. Estos programas se han implementado en muchos estados de EUA, en la Unión Europea, en Nueva Zelanda y en Australia [102].

El banco mundial reportó en el 2018 que 51 iniciativas de políticas de precios de carbono se han implementado o están agendadas para realizarse próximamente, las cuales se componen por 25 de comercio de emisiones y 26 de impuestos de carbono. Estas 51 iniciativas contemplan 11 giga toneladas de dióxido de carbono equivalente (cerca del 20% de las emisiones a nivel mundial). El valor monetario estimado de estas iniciativas es de \$82 mil millones de dólares y representan un incremento del 56% comparadas con las del 2017 [105]. Sin embargo, algunos países utilizan las ganancias de estas iniciativas para engrosar el presupuesto gubernamental y no se garantiza que se utilicen directamente en estrategias para la reducción de emisiones [106]. Además, en muchos países siguen existiendo subsidios en combustibles fósiles que hacen difícil la incorporación de tecnologías renovables en su sistema energético [107]. Actualmente, los precios del carbono varían substancialmente desde US\$1/tCO₂ hasta un máximo de \$139/tCO₂; no obstante, la mayoría de las iniciativas tienen un costo menor al que se requiere para lograr los objetivos del acuerdo de Paris (entre US\$40 y US\$80) [105].

Es evidente que se tiene una potencial solución en los precios del carbono; sin embargo, una limitación de la monetización de las emisiones es que los precios y/o los impuestos se aplican generalmente en una escala globalizada, es decir, se fija un precio general por las emisiones sin importar el tipo de actividades económicas que afecten o la escala a la que se realicen las mismas. Además, al no ser un mercado maduro, muchas veces los precios no reflejan su verdadero valor para ciertas actividades [108]. Existen muchas razones porque algunos países son cautelosos al incluir este tipo de políticas, especialmente porque los mercados de carbono no se pueden sostener sin la participación y asistencial del gobierno [109]. Además, impulsar en el mercado alternativas relativamente costosas para las tecnologías energéticas aumenta

el costo social general de la protección climática y reduce la eficiencia de la intervención política. De esta manera, los subsidios a la energía alternativa también podrían reducir la aceptación pública de las energías renovables y, por lo tanto, reducir el margen político para la protección del clima en general [110].

El transporte, la producción de electricidad y la generación de calor son algunos de los principales emisores de gases de efecto invernadero en la mayoría de los países. Sin embargo, una de las actividades clave para lograr con los acuerdos de París es la reducción de la quema controlada de gases combustibles de desecho. Esta actividad se realiza por seguridad, principalmente durante situaciones anormales, teniendo como objetivo alcanzar una eficiencia de combustión de 98% [111]. Sin embargo, es responsable de 400 millones de toneladas de bióxido de carbono equivalente por año [112], lo que representa una cantidad significativa de emisiones con la que contribuyen anualmente todo los países exploradores y productores de combustibles fósiles.

El banco mundial tiene una iniciativa especial para atender este problema *The global gas flaring reduction partnership* y se han propuesto algunas iniciativas de ley que promuevan la minimización de estas emisiones. Por otro lado, debido a la magnitud de este problema nivel mundial se han propuesto diversas alternativas para reducir y de ser posible eliminar este problema. Stanley [113] examinó la implementación de la tecnología en Nigeria para convertir el gas natural, que típicamente se quema como si fuera un desecho, en combustibles más adecuados para su transporte y almacenamiento como gasolina, diésel y queroseno. Comodi y col. [114] propusieron un sistema de recuperación de gases de desecho como alternativa para mejorar la eficiencia energética en las refinerías y disminuir sus emisiones. Específicamente, seleccionaron un compresor de anillo líquido, que es una máquina volumétrica rotativa que utiliza un fluido secundario para comprimir el gas. Como era de esperar, la presencia de gas inerte y sulfuro de hidrógeno, y una tasa de flujo y composición muy variables fueron los principales problemas; sin embargo, reportaron ventajas ambientales y económicas usando este método. De igual forma, Hajizadeh y col. [115] la evaluación de tres métodos para la recuperación de GCD (licuefacción de GCD, producción de gas LP y compresión y recirculación de los GCD) en una refinería de Irán y los resultados muestran que usando métodos de recuperación de GCD se puede recuperar hasta un 80% de ellos. Otra popular alternativa para el aprovechamiento de los GCD es la producción de

electricidad, la cual tiene muchas ventajas como la reducción en el consumo de combustible, la facilidad de adaptar equipo para este uso y el costo accesible.

Para producir electricidad se utilizan frecuentemente equipos de cogeneración por su eficiencia superior a los sistemas convencionales y porque estos sistemas pueden proveer una amplia gama de servicios auxiliares como calentamiento, enfriamiento y electricidad. también, porque los sistemas de cogeneración pueden consumir diferentes combustibles y porque la tecnología disponible actualmente puede ser adaptada para el uso de GCD [116]. Heidari y col. [116] presentaron el análisis de dos sistemas factibles para la producción de electricidad a partir de GCD considerando un flujo variable, gases con un LHV bajo y el uso de gas natural como combustible suplementario. Además, es posible encontrar ejemplos reportados de generación de electricidad usando corrientes de GCD en combinación con políticas de carbono; por ejemplo, Kazi y col [117] propusieron un modelo de optimización para dimensionar un sistema de cogeneración que aproveche los GCD de un planta de etileno para satisfacer su demanda de electricidad y calentamiento considerando impuestos de carbono, como resultado se obtienen beneficios económicos y ambientales con el sistema propuesto. Más tarde, Kazi y col. [118] extendieron este modelo para considerar la integración del tratamiento de agua con el aprovechamiento energético de los GCD y observaron un claro aumento en la eficiencia global de la planta. Todos los métodos mencionados tienen ventajas y desventajas y la tecnología seleccionada para la reducción y aprovechamiento de los GCD depende de las características de los mismos; sin embargo, se ha demostrado que la producción de electricidad es superior desde un punto de vista económico [119]. Esto fue analizado por Rahimpour y Jokar [119], quienes compararon varias alternativas como el gas-a-liquido, la recuperación/separación de gases y la generación de electricidad en la refinería de gas de Farashban para la recuperación de los GCD en lugar de la alternativa convencional de quemarlos en atmósfera abierta siendo la producción de electricidad es el método que brinda las tasas de retorno más altas y las mejores ganancias. Zolfaghari y col. [120] confirmaron esto mismo cuando compararon la producción de electricidad contra el proceso gas-a-liquido y contra la conversión de GCD en etileno.

En este trabajo se propone estudiar el efecto económico y ambiental de la monetización de emisiones cuando se diseña un nuevo sistema de cogeneración que puede ser alimentado parcialmente con corrientes combustibles de desecho (cuando sea económicamente viable).

Se compara una formulación multiobjetivo basada en una solución compromiso que balancea la prioridad de las diferentes partes involucradas y/o los objetivos que se buscan lograr (ambientales, económicos, sociales, etc.) contra la opción de considerar todo lo anterior en una típica función económica (mono-objetivo) que involucra aspectos ambientales mediante la monetización de las emisiones a través de impuestos de carbono y de la comercialización de emisiones. Se demuestra que es más eficiente utilizar una solución compromiso para alentar el uso de tecnologías benéficas para el medio ambiente.

Se considera un parque industrial que tenga un conjunto de corrientes combustibles de desecho cuya mezcla proporciona una fuente continua de energía que puede ser utilizada como alimentación suplementaria en un sistema de cogeneración que se busca diseñar. El sistema de cogeneración tiene como objetivo satisfacer al menos las necesidades energéticas del complejo industrial y se tiene la posibilidad de producir una cantidad adicional de energía para satisfacer un mercado externo, siempre y cuando sea benéfico para el sistema. La mezcla de gases de desecho normalmente es quemada en atmosfera abierta sin tener ningún beneficio y se busca utilizarlo para disminuir el consumo de combustible fresco (gas natural) que requiere el sistema de cogeneración (ver Fig. 4.1).

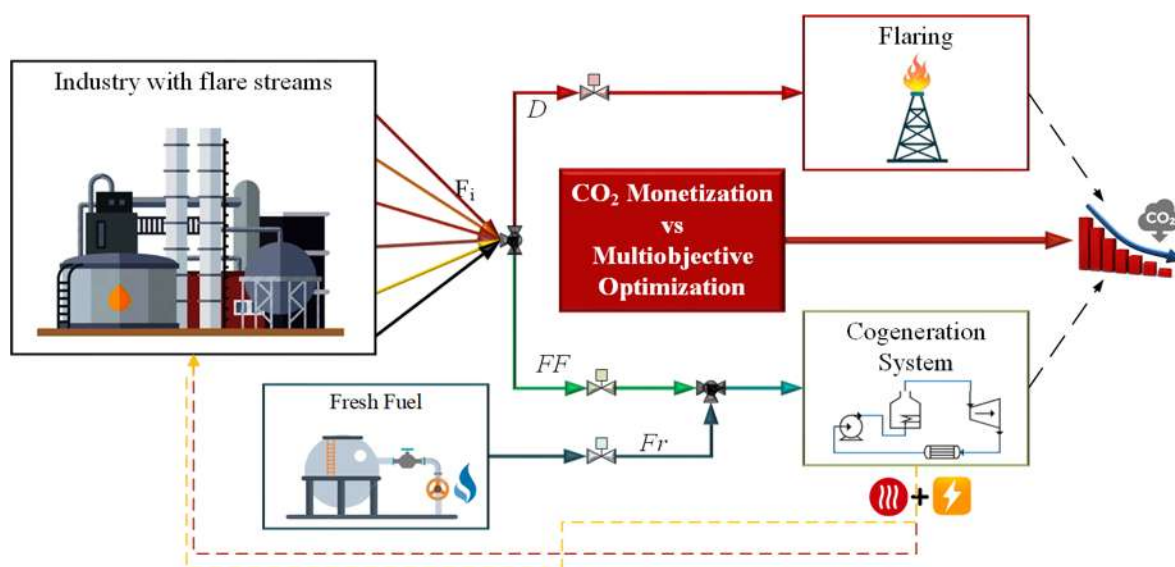


Figura 4.1: Superestructura del sistema propuesto.

La corriente de la mezcla de los gases combustibles de desecho tiene tres posibles destinos. El primero es quemarse sin ser aprovechada como se hace convencionalmente, el segundo es mezclarla con el combustible principal para alimentar el sistema de cogeneración y la tercera es dividirse de tal forma que una fracción de la corriente se queme de forma convencional y el resto se alimente como combustible suplementario.

4.1.1 Modelo Matemático

El modelo matemático que se presenta está basado en un trabajo previo [10], [11]. El modelo incluye balances de materia y energía para representar los mezcladores y el equipo principal basándose en la superestructura que se muestra en la Fig. 4.1. El modelo también incluye funciones de costo y ecuaciones para el cálculo de las emisiones de CO₂ que genera el sistema. A continuación, se presenta el modelo matemático:

La primera expresión es el balance de masa total. La corriente que lleva la mezcla de gases combustibles de desecho (F) se puede quemar en atmosfera abierta (D), enviar al sistema de cogeneración o dividirse para usar una fracción y quemar el resto.

$$F = D + FF \quad (4.1)$$

Después se incluye un conjunto de ecuaciones para el sistema de cogeneración. El calor que se produce en la caldera es igual a la suma de la energía que resulta de la combustión del combustible fresco más la energía que resulta del aprovechamiento de las corrientes de desecho por la eficiencia del equipo.

$$Q^{boil} = \eta^{boil} (FrH^{Fr} + FFH^{FF}) \quad (4.2)$$

De igual forma se utilizan balances de energía para calcular la potencia y el calor en los equipos que integran el ciclo.

$$Q^{boil} = \eta^{boil} \dot{m}(h_1 - h_4) \quad (4.3)$$

$$P^{turb} = \eta^{turb} \dot{m}(h_1 - h_2) \quad (4.4)$$

$$Q^{cond} = \eta^{cond} \dot{m}(h_2 - h_3) \quad (4.5)$$

$$P^{pump} = \eta^{pump} \dot{m}(h_4 - h_3) \quad (4.6)$$

Las ganancias por la electricidad generada en el ciclo se calculan tomando en cuenta la potencia de la turbina y precio unitario de la electricidad.

$$Sales^{elect} = P^{turb} \text{price}^{elect} \quad (4.7)$$

El flujo de vapor en el ciclo se puede calcular en función de la potencia de la turbina y está restringido por un valor máximo conocido.

$$\dot{m} = C1_m P^{turb} + C2_m \quad (4.8)$$

$$\dot{m} \leq \dot{m}^{max} \quad (4.9)$$

Los costos de operación del condensador, equipo de bombeo y combustible fresco se determinan como se muestra a continuación, respectivamente.

$$OC^{cond} = Q^{cond} \text{price}^{cw} \quad (4.10)$$

$$OC^{pump} = P^{pump} \text{price}^{power} \quad (4.11)$$

$$OC^{rep} = Fr H^{Fr} \text{price}^{rep} \quad (4.12)$$

El costo asociado a utilizar corrientes combustibles de desecho (*flares*) se calcula en función del precio del combustible fresco y de las propiedades y la cantidad de gas que se utiliza [121].

$$OC^{Flow} = 2.592 \times 10^6 q CSU \quad (4.13)$$

$$CSU = A \cdot CEPCI + B \cdot CSF \quad (4.14)$$

$$A = (2.5 \times 10^{-5} \text{LHV}^{0.77}) (q)^{-0.23} \quad (4.15)$$

$$B = -6 \times 10^{-4} \text{LHV} \quad (4.16)$$

Los costos de capital del equipo principal se calcularon usando funciones previamente publicadas [122].

$$CC^{boil} = CF^{boil} + CV^{boil} (Q^{boil})^{c^{boil}} \quad (4.17)$$

$$CC^{turb} = CF^{turb} + CV^{turb} (P^{turb})^{c^{turb}} \quad (4.18)$$

$$CC^{cond} = CF^{cond} + CV^{cond} (Q^{cond})^{c^{cond}} \quad (4.19)$$

$$CC^{pump} = C1^{pump} + C2^{pump} (P^{pump})^{c^{pump}} \quad (4.20)$$

La potencia que se produce en el ciclo Rankine debe de estar entre dos límites, donde el límite inferior es la demanda del complejo industrial y el límite superior es esta demanda más una demanda de un mercado externo.

$$P^{turb} \geq EREQ \quad (4.21)$$

$$P^{turb} \leq EMAX \quad (4.22)$$

Las emisiones relacionadas al sistema de cogeneración toman en cuenta las emisiones del combustible fresco y del desecho combustible que se utiliza.

$$GHGCS = \sum_c \left(\frac{FF X_c Y_c}{PM_c} \right) (PM_{CO_2}) + \sum_{cFr} \left(\frac{Fr_{t,s} X_{cFr} Y_{cFr}}{PM_{cFr}} \right) (PM_{CO_2}) \quad (4.23)$$

Las emisiones del sistema de quema controlada de gases de desecho se calculan con la siguiente ecuación.

$$GHGFS = \sum_c \left(\frac{DX_c Y_c}{PM_c} \right) (PM_{CO_2}) \quad (4.24)$$

Por tanto, las emisiones totales del sistema resultan en la suma de las emisiones del sistema de cogeneración y las del sistema de quema controlada de gases.

$$TGHG = GHGCS + GHGFS \quad (4.25)$$

Se resuelven tres casos diferentes para analizar el efecto de la monetización de las emisiones contra una solución compromiso que busca un equilibrio entre la minimización de emisiones

y la maximización de ganancias. La función objetivo cambia para cada caso de estudio como se muestra a continuación.

El primer caso tiene como función objetivo maximizar las ganancias y se estimula la minimización de emisiones dando una bonificación económica por cada tonelada de CO₂ equivalente que se reduce con respecto a la forma convencional en la producción de energía (ver Tabla 4.1).

Caso 1

$$\begin{aligned}
 Profit = & Sales^{elect} - OC^{cond} - OC^{pump} - OC^{rep} \\
 & - K_F \left\{ \begin{array}{l} CC^{boil} + CC^{turb} \\ +CC^{cond} + CC^{pump} \end{array} \right\} \\
 & + CBon(GHG^{UB} - TGHG)
 \end{aligned} \tag{4.26}$$

Tabla 4.1: Valores de estímulos económicos usados [16].

Escenario	1	2	3	4	5	6
Precio (USD/ton)	3	10	15	30	80	120

El segundo caso busca, de igual manera, maximizar las ganancias, pero la reducción de emisiones es motivada por una penalización económica por cada tonelada de CO₂ generada (ver Tabla 4.2).

Caso 2

$$\begin{aligned}
 Profit = & Sales^{elect} - OC^{cond} - OC^{pump} - OC^{rep} \\
 & - K_F \left\{ \begin{array}{l} CC^{boil} + CC^{turb} \\ +CC^{cond} + CC^{pump} \end{array} \right\} \\
 & - CTax(TGHG)
 \end{aligned} \tag{4.27}$$

Tabla 4.2: Valores de penalizaciones económicas usadas [16].

Escenario	1	2	3	4	5	6
Precio (USD/ton)	10	15	25	32	41	52

El tercer caso busca simultáneamente maximizar ganancias y minimizar emisiones sin tomar en cuenta la monetización. En este caso se asignan diferentes pesos a cada objetivo para analizar su comportamiento (ver Tabla 4.3).

Caso 3

$$FO = w_1 \left(\frac{\text{Profit}^{UB} - \text{Profit}}{\text{Profit}^{UB} - \text{Profit}^{LB}} \right) + w_2 \left(\frac{\text{TGHG} - \text{TGHG}^{LB}}{\text{TGHG}^{UB} - \text{TGHG}^{LB}} \right) \quad (4.28)$$

Tabla 4.3: Prioridades de los objetivos para la ecuación multiobjetivo

Escenario	1	2	3	4	5	6	7
w1	1	0.8	0.6	0.5	0.4	0.2	0
w2	0	0.2	0.4	0.5	0.6	0.8	1

4.1.2 Parámetros

Se considera un complejo industrial (como el que se muestra en la Fig. 4.1) con un flujo continuo de una mezcla de gases combustibles de desecho (2.22 kg/s) cuya composición se muestra en la Tabla 4.4. Esta corriente originalmente es quemada sin aprovechar su energía y el calor que se genera se disipa en la atmosfera. Se busca diseñar un sistema de cogeneración que aproveche este desperdicio energético limitando la capacidad instalada entre 32 MW y 64 MW. La cantidad disponible de GCD no es suficiente para satisfacer los requerimientos de potencia por sí mismos, por lo que hay una corriente principal de combustible fresco (gas natural), que puede suministrar parcial o totalmente la energía necesaria. Es decir, el sistema que se propone le da tres opciones a la corriente de GCD, mezclarse completamente con combustible fresco para alimentar el sistema de cogeneración, quemarse en atmosfera abierta como se hace actualmente o dividirse en dos corrientes una que se quema como se hace convencionalmente y otra que alimenta al sistema de cogeneración. La opción que se seleccioné dependerá de los beneficios económicos y/o ambientales que se tengan del aprovechamiento de las GCD.

Se analizaron tres casos con tres diferentes funciones objetivo, el primer caso pretende estudiar el efecto que tienen los incentivos económicos en la implementación de tecnologías

para la reducción de emisiones de efecto invernadero (comercialización de emisiones). Para ello, se utilizarán diferentes precios unitarios por la reducción de emisiones (véase Tabla 4.1). El segundo caso utiliza diferentes valores de penalizaciones económicas (impuestos de carbono) para estudiar el efecto de que tienen en la disminución de emisiones (ver Tabla 4.2). Para el tercer caso se asignan diferentes niveles de prioridad a los objetivos económico y ambiental (w_1 y w_2 , ver Tabla 4.3) para mostrar los diferentes efectos que tiene la preferencia de uno de ellos (minimizar emisiones o maximizar ganancias) en las características del sistema que se busca diseñar.

Tabla 4.4: Propiedades de las corrientes usadas en el análisis.

GCD			Combustible fresco		
Flujo [kg/s]	Masa molecular	Contenido energético [GJ/ton]	Flujo [kg/s]	Masa molecular	Contenido energético [GJ/ton]
2.22	39.92	33.44	Unlimited	17.29	45.9

Tabla 4.5: Composición de los GCD

Gas	Composición %	Gas	Composición %
Nitrógeno	0.60	n-pentano	2.60
Agua	3.10	Pentano	2.70
Monóxido de carbono	0.00	Benceno	3.20
Dióxido de carbono	28.00	Tolueno	2.80
Metano	36.00	Xileno	2.20
Etano	7.20	Naftaleno	2.50
Propano	4.90	Iso-buteno	1.40
n-butano	2.80		

La Tabla 4.4 y la Tabla 4.5 muestran las propiedades físicas y químicas, el flujo y la composición del combustible principal (gas natural) y el combustible suplementario (gases combustibles de desecho), las cuales fueron adaptadas de la literatura para este caso de estudio [116].

A continuación, se presentan los resultados para el caso de estudio y se presentan graficas que muestran tanto el efecto que tiene la monetización de las emisiones como los resultados obtenidos con la solución compromiso.

4.1.3 Resultados

El modelo matemático que se propone es no lineal y fue resuelto usando el lenguaje de modelación matemática JuMP con el *solver* Ipopt.

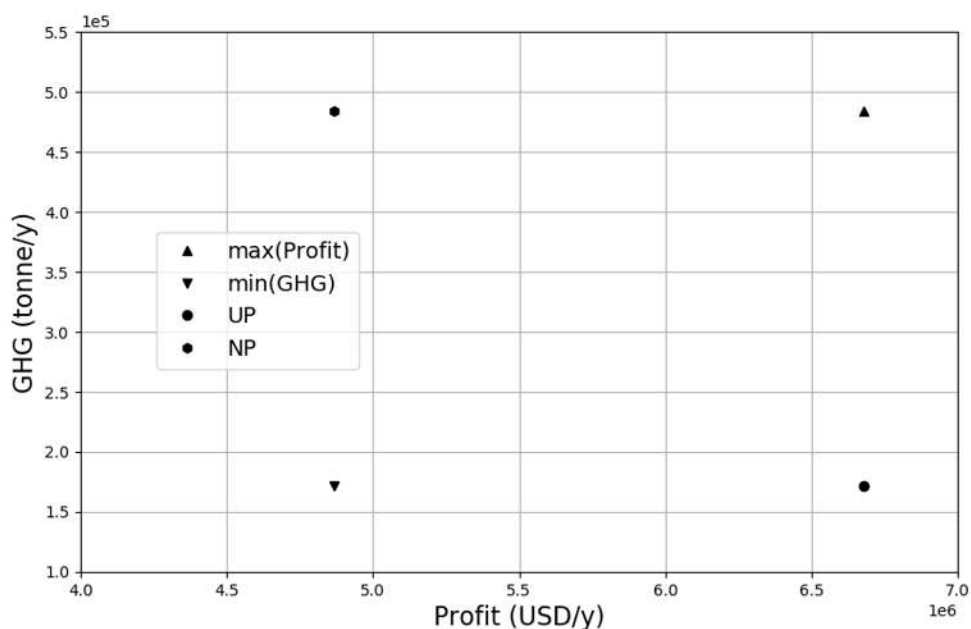


Figura 4.2: Puntos de referencia.

La Fig. 4.2 muestra los valores que sirven de referencia. Estos valores se obtienen cuando directamente se maximizan las ganancias $\max(Profit)$ y se minimizan las emisiones $\min(GHG)$. En el caso $\max(Profit)$ la solución óptima incluye seleccionar una capacidad instalada de 64MW y los GCD no son utilizados como combustible suplementario debido al

costo de operación e inversión que esto implica. Por tanto, este punto es el que tiene los valores máximos de CO_2 equivalente y las mejores ganancias. El caso opuesto es en el que se minimizan las emisiones, $\min(GHG)$, en donde el sistema selecciona una capacidad instalada de 32 MW para el sistema de cogeneración y toda la corriente disponible de GCD es aprovechada sin importar el costo que esto implique, por lo que se tiene las emisiones más bajas posibles, pero también se obtienen las peores ganancias.

A partir de estos resultados se pueden definir la solución de nadir (NP) y el punto utópico (UP), dichos puntos son soluciones no factibles del sistema. Sin embargo, sirven como referencia ya que lo deseable es tener una solución lo más cercana al punto utópico (máximas ganancias y mínimas emisiones) y lo más alejada a la solución de Nadir (mínimas ganancias y máximas emisiones).




Figura 4.3: Resultados de los diferentes precios en el comercio de emisiones (Caso 1)

La Fig. 4.3 representa la solución que se obtiene cuando se maximiza la ecuación (4.26) para cada uno de los valores que se muestran en la Tabla 4.2. Los triángulos azules representan la solución cuando se usan estímulos económicos provenientes del comercio de emisiones. Se puede observar que cuando las emisiones tienen un valor de entre 3 y 15 dólares por tonelada

no resulta atractivo invertir en el aprovechamiento de los GCD. No obstante, cuando el precio se eleva en 30 por tonelada se logra una disminución en las emisiones del 35% pero solamente porque se reduce la capacidad instalada del sistema de generación de 64 MW a 32 MW, es decir, se vuelve más atractivo disminuir emisiones que producir electricidad, pero esto no es suficiente para que se vuelva atractivo utilizar GCD. Como se muestra en la Fig. 4.3 es necesario aumentar los beneficios económicos por la reducción de emisiones por encima de los 80 dólares por tonelada para que comience a ser atractivo el uso de GCD y se disminuyan las emisiones. Es importante recordar que 120 dólares por tonelada que representa el valor máximo que se proyecta que pueden alcanzar estas bonificaciones económicas [16].




Figura 4.4: Resultados utilizando penalizaciones económicas por la generación de emisiones (Caso 2)

La Fig. 4.4 presenta los resultados de maximizar la ecuación (4.27) cuando se utilizan las penalizaciones económicas (impuestos de carbono) de la Tabla 4.3. Se observa que las penalizaciones correspondientes a los escenarios 1 a 3 (10, 15 y 25 USD/ton) no promueven la disminución de las emisiones del sistema y se alcanza la generación máxima de emisiones

en ambos casos. Cuando la penalización supera los 25 dólares por tonelada la ganancia es nula y se registran pérdidas económicas. Para los escenarios 4 a 6 (32, 41 y 52 USD/ton) se reducen las emisiones, pero únicamente porque la capacidad instalada seleccionada pasa del límite superior de 64 MW al límite inferior de 32 MW por lo que no se promueve el uso de GCD y no es posible minimizar las emisiones usando esta estrategia.

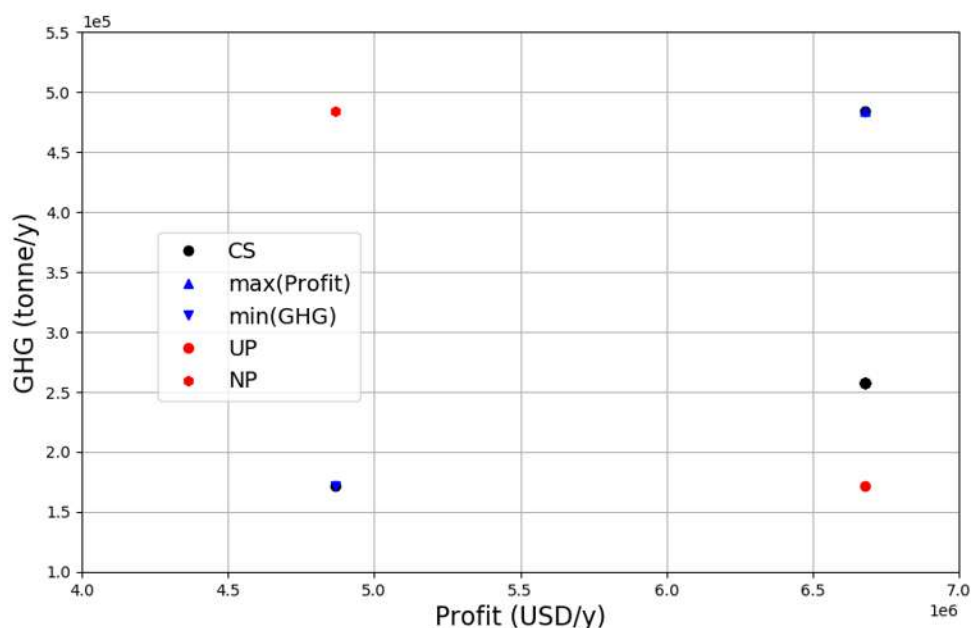


Figura 4.5: Resultados de la solución compromiso (Caso 3)

En la Fig. 5 se encuentran los resultados de maximizar la solución compromiso (CS) asignando diferentes pesos a las emisiones y a las ganancias, es decir, maximizando la ecuación (28). Los puntos rojos y triángulos azules representan los resultados de referencia. Los puntos negros representan la solución compromiso (CS). Los puntos extremos de la solución compromiso (escenarios 1 y 7 de la Tabla 3) coinciden con las soluciones de maximizar las ganancias y minimizar las emisiones. Las soluciones de los escenarios 2 a 6 se encuentran agrupadas en la misma posición (punto negro de Fig. 4.5). La capacidad seleccionada del sistema de cogeneración para este caso es de 48.29 MW logrando un excelente balance entre disminución de emisiones y maximización de ganancias. Las

emisiones que se tienen en el caso tres son apenas 15% superiores al valor mínimo y las ganancias alcanzan su valor máximo posible lo que corresponde a aprovechar en su totalidad el flujo de GCD. Lo anterior se logra sin la necesidad de utilizar ninguna política económica asociada a la disminución de las emisiones.

Los resultados muestran que la solución compromiso es superior a los métodos convencionales cuando se busca alentar el uso de nuevas tecnologías para la reducción de emisiones de gases de efecto invernadero. El comercio de emisiones requiere una inversión directa muy significativa para que se vuelva atractiva la propuesta y los impuestos de carbono hacer que la opción se vuelva inviable desde un punto de vista económico. Sin embargo, esto no quiere decir que las políticas sean malas o que deberían desaparecer. El uso combinado de las políticas de carbono estudiadas en este trabajo y la optimización multiobjetivo tiene un gran potencial que permitiría reducir la inversión o las penalizaciones necesarias para lograr una disminución en las emisiones de un proceso como se demostró en la Ref. [58].

Capítulo 5

Procesos productivos, problemas MILP multiobjetivo

En este trabajo se aborda la selección óptima de la estructura de generación de energía renovable necesaria para sustituir plantas de potencia existentes en un sistema eléctrico a gran escala. Se desarrolló un modelo de optimización mixto entero lineal multiobjetivo que puede ser adaptado a diferentes sistemas de generación eléctrica nacionales. El modelo de optimización matemática que se propone considera simultáneamente restricciones técnicas, la disponibilidad de recursos energéticos en las diferentes localizaciones, el consumo de agua potable en función de las tecnologías seleccionadas y la localización, las emisiones de gases de efecto invernadero directas y de ciclo de vida y los costos de inversión y de operación. Se presenta un caso de estudio del Sistema Eléctrico Peninsular de España debido a que se avecina el desmantelamiento de sus centrales térmicas nucleares y de carbón. Los resultados muestran la localización, el tipo de tecnología, la capacidad y la estructura de generación necesarias para combinar técnica y sustentablemente las nuevas plantas con las existentes.

5.1 Transición energética sustentable

El consumo de electricidad en el mundo está incrementando en los sectores residencial y comercial debido al crecimiento poblacional y al incremento en el acceso a este servicio de países ajenos a la OECD. Además, el uso de la electricidad en la industria y el transporte han tenido un incremento notable en los últimos años como resultado de la demanda de productos y el incremento de los vehículos eléctricos [123]. El calentamiento global ha hecho evidente la necesidad de tener sistemas de producción de electricidad más sustentables y esto ha derivado en acuerdos internacionales [124] que buscan cambiar la forma en la que se transforma la energía. El uso de recursos no sustentable se debe minimizar y las tecnologías de energía renovable tienen que tomar un papel protagónico en el suministro de energía mundial para lograr reducir la emisión de gases de efecto invernadero (GEI) y mitigar el cambio climático. Ejemplo de ellos se observa en la Unión Europea, que se ha planteado reducir su emisión de GEI en 20% para el 2020, 40% para el 2030, 60% para 2040 y 80% para 2050 en comparación con los niveles registrados en 1990. Como se mencionó anteriormente la electricidad es una de las formas de energía más consumidas en el mundo, por lo tanto, la transición energética de combustibles fósiles a recursos energéticos renovables en sistemas eléctricos de potencia es uno de los principales asuntos que se deben de atender para lograr los objetivos para el desarrollo sostenible. La electrificación a gran escala de los sectores de consumo final como las viviendas, la industria y el transporte, así como la descarbonización del sector eléctrico, son claves para la transición energética [125]. Sin embargo, existen otros problemas que forman parte de los objetivos de desarrollo sostenible como el manejo sustentable del agua, el desarrollo económico inclusivo, el acceso a la energía para todos, etc. Los cuales están relacionados con la transición energética y el calentamiento global, entonces, ¿Cómo satisfacer una creciente demanda de energía, logrando un suministro óptimo que impulse el crecimiento económico sin comprometer el medio ambiente o los recursos naturales y respetando los objetivos de desarrollo sostenible? [126]. En este sentido diversos trabajos han realizado propuestas en este sentido a diferentes escalas. Algunos autores se han centrado en determinar la combinación de energías renovables que pueda satisfacer una demanda de energía hora con hora [127]. Otros han optimizado un sistema de plantas de potencia para lograr la generación de energía con 100% de renovables al mínimo costo posible considerando una meta secuencial de reducción de

emisiones en diferentes etapas [128] o minimizando el costo considerando restricciones de operación, metas de disminución de emisiones y el efecto en la variación de los costos de las tecnologías renovables con respecto al tiempo[129]. En el caso de sistemas a gran escala, Pleßmann y Blechinger [130] propusieron una ruta viable para la descarbonización de los proveedores de electricidad de 18 regiones interconectadas de la Unión Europea para alcanzar la meta de tener 98.5% de generación con renovables (en promedio) para 2050, pero para lograrlo se requiere un incremento en el costo de la electricidad de 35%. De igual forma Gerbaulet y col. [131] analizaron diferentes escenarios del sector eléctrico europeo encontrando que la transición energética al uso de energías renovables no solo es factible sino que puede tener un precio atractivo bajo determinadas condiciones. También, se ha estudiado ampliamente el efecto de políticas gubernamentales en la transición energética de un sistema nacional de potencia eléctrica para diferentes naciones [132], [133]. En el contexto de un sistema nacional de generación eléctrica en la literatura se han reportado varios casos. Por ejemplo, Shahid y col [134] estudiaron las implicaciones de diferentes escenarios de la transición energética para el sistema eléctrico de Pakistán, Hansen y col. [135] demostraron que es posible tener una estructura de generación 100% renovable en Alemania desde un punto de vista técnico y económico y Vidal-Amaro y col. [136] determinaron la estructura de generación óptima de tecnologías renovable y fósiles en el sistema eléctrico mexicano tomando en cuenta la demanda y generación que se puede tener cada hora. Los países que lideran la transición energética son Alemania, España, Italia, china y algunos estados de Estados Unidos debido a sus efectivas políticas energéticas [137], por lo tanto, diversas investigaciones han analizado el efecto de utilizar políticas similares en su otros países [137]–[139].

Este trabajo se enfoca en la transición energética de un sistema de potencia eléctrica nacional que donde se busca aprovechar los recursos energéticos renovables disponibles en regiones seleccionadas y considerando las características geográficas de los potenciales sitios de instalación de nuevas plantas y la infraestructura de generación ya instalada. Como caso de estudio se seleccionó el Sistema de Electricidad Peninsular de España (SEPE). El SEPE se ha estudiado y diferentes trabajos han analizado la transición energética buscando la mejor ruta para la transición y la mejor combinación de tecnologías renovables. Victoria y Gallego-Castillo [128] simularon dos rutas para alcanzar los objetivos de generación de renovables

en el SEPE entre 2017 y 2030. García-Gusano y col. [140] desarrollaron un conjunto de prospectos basados en el análisis de ciclo de vida de las tecnologías de generación eléctrica del sistema español de 2014 a 2050 en donde las plantas nuevas estaban predeterminadas y se modelaban usando conjuntos de valores enteros. González-Calvet y col. [141], [142] estudiaron el desarrollo óptimo de las energías renovables en España para 2030 usando optimización lineal y encontraron que para lograr una participación extensiva de fuentes de energía inciertas requiere de una estructura de apoyo robusta para permitir una la operación continua. Es importante tomar en cuentas que tener un gran porcentaje de energías renovables con fuentes intermitentes, como la energía solar fotovoltaica y la eólica, en la estructura de generación de un sistema de potencia es atractivo desde un punto de vista ambiental por su baja cantidad de emisiones; sin embargo, esto puede significar un reto operacional significativo [143] y la explotación extensiva de otros recursos naturales [144]–[149].

Los trabajos mencionados anteriormente han contribuido notoriamente, demostrando que es factible realizar una transición energética que logre las metas de reducción de emisiones; no obstante, el consumo de agua en las diferentes plantas no sea considerado en la transición energética a pesar de que muchos trabajos han demostrado la importancia de considerar el nexo agua-energía en la generación de electricidad [150]–[152]. Por ejemplo, la demanda de agua del sector energético en la unión europea representa el 42% de la extracción total de agua, superando a sectores como el residencial y el agrícola [153]. La optimización multiobjetivo ha demostrado ser de utilidad para analizar la relación entre objetivos que se contraponen utilizando soluciones compromiso en sistemas de generación eléctrica [154]–[156]. En este trabajo se desarrolló un modelo mixto entero lineal multiobjetivo para abordar la sustitución de plantas de potencia pertenecientes a un sistema de generación nacional con plantas renovables. La principal aportación del trabajo es considerar simultáneamente objetivos económicos y ambientales en planeación óptima de la transición energética, específicamente, considerar el consumo de agua en sistemas eléctricos de potencia como factor de decisión para seleccionar el tamaño, tipo y localización de plantas de energía renovable con menor impacto en este recurso. Los trabajos previos se han enfocado en alcanzar metas preestablecidas sobre la mitigación de emisiones de gases de efecto invernadero. No obstante, en este trabajo se demuestra que considerar el consumo de agua conduce a soluciones que disminuyen el impacto a este valioso recurso sin la necesidad de

que se pierda de vista el objetivo de la minimización de emisiones. El modelo de optimización que se propone minimiza el costo anual, las emisiones de gases de efecto invernadero y el consumo de agua mientras considera restricciones técnicas y de operación, la disponibilidad de recursos renovables en diferentes sitios, el consumo de agua en función del tipo y la posición geográfica de las nuevas plantas, emisiones directas y de ciclo de vida, así como, costos de inversión y operación buscando que la solución óptima del modelo conteste las siguientes preguntas:

¿Cuál es la estructura de generación óptima que puede sustituir determinadas plantas en sistemas eléctricos de potencia nacionales?

¿Dónde se deben instalar las plantas de potencia nuevas para tomar ventaja de los recursos energéticos y las condiciones geográficas para satisfacer la demanda de electricidad?

¿Cómo minimizar el consumo de agua y las emisiones de gases de efecto invernadero al menos costo posible?

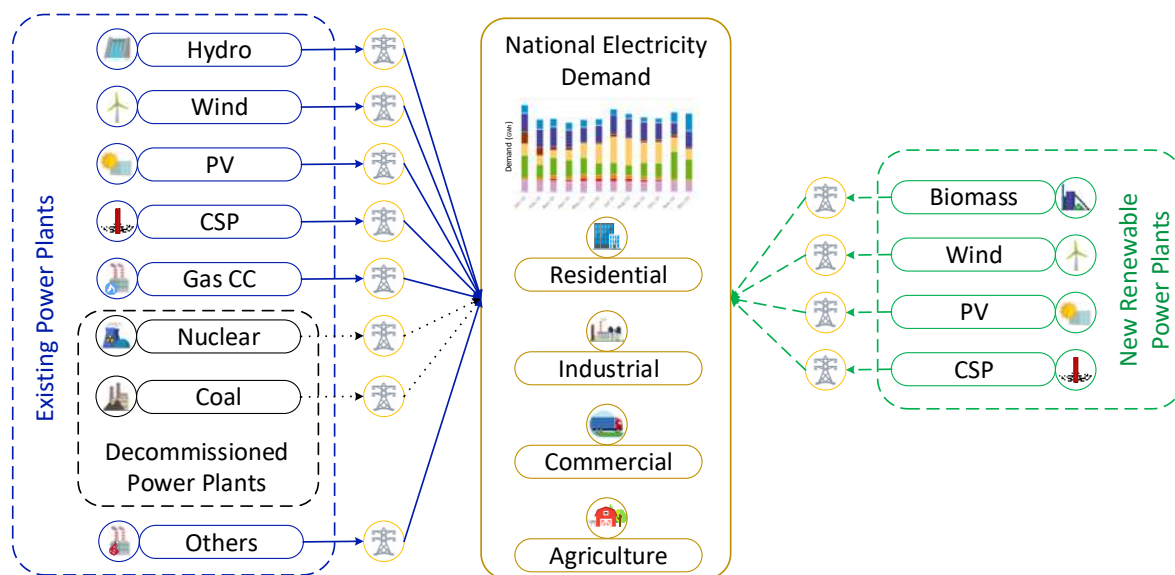


Figura 5.1: Superestructura de la transición energética propuesta.

La Fig. 5.1 muestra la superestructura de la transición energética en un sistema de potencia eléctrica donde un número predefinido de plantas cerrara debido a factores ambientales,

técnicos, sociales y/o económicos. El objetivo es sustituir las plantas cerradas con la mejor combinación de plantas de energía renovable; sin embargo, es necesario tomar en cuenta la flexibilidad y el factor de planta de las nuevas plantas para suministrar una demanda de electricidad que varía a lo largo del año.

5.1.1 Modelo matemático

Se desarrolló un modelo de optimización mixto entero lineal para seleccionar la estructura de generación óptima que considere tecnologías renovables para sustituir plantas de potencia desmanteladas y las plantas existentes del sistema. En esta sección se presentan los balances de materia y energía, restricciones técnicas e indicadores de sustentabilidad (consumo de agua y generación de emisiones).

Conjuntos

Primero se definirán los conjuntos usados en el modelo:

EPP: Plantas de potencia existentes. Son las plantas que ya se encuentran instaladas y operan para satisfacer la demanda de electricidad. Cada elemento de este conjunto tiene sus características predefinidas como el tipo de tecnología, la localización y la capacidad.

NPP: Plantas de potencia nuevas. Son las tecnologías disponibles para sustituir a las plantas desmanteladas. Cada una de estas plantas tienen diferentes ventajas y desventajas que juegan un importante factor de decisión para minimizar el costo y la sustentabilidad del sistema.

NBM: Nuevas plantas térmicas de biomasa. Es un subconjunto de NPP.

NPV: Nuevas plantas solares fotovoltaicas. Es un subconjunto de NPP.

NCS: Nuevas plantas de concentración solar. Es un subconjunto de NPP.

NEO: Nuevas plantas eólicas. Es un subconjunto de NPP.

CT: Sitios potenciales para instalar una planta nueva de potencia. Se tienen diferentes sitios en los que se puede instalar más de una tecnología. Cada sitio cuenta con diferentes características y disponibilidad de recursos energéticos que hacen factible o no la instalación de plantas de potencia como la biomasa, la velocidad del viento y la irradiación solar.

BP: Sitios productores de biomasa. Cada BP produce una cantidad de biomasa en cada periodo, sin embargo, la biomasa puede ser transportada en caso de que sea adecuado.

BRM: Tipos de biomasa disponibles. Pueden tomarse en cuenta los diferentes tipos de biomasa disponibles en los BP. Además, se considera la posibilidad de utilizar una mezcla de ellas si es necesario.

T: Periodos de tiempo en los que se discretiza el problema.

Demanda de energía

La demanda de energía es un parámetro (DEM_t) que debe ser igual a la suma de la energía generada en las EPP y las NPP. Es importante resaltar que la capacidad de las EPP no es suficiente para satisfacer la demanda debido a que se asume que algunas plantas son desmanteladas y por tanto las NPP tienen que reemplazarlas para satisfacer la demanda. La energía generada en cada periodo por las EPP se calcula en función de la capacidad instalada de cada planta (IC_{ep}) y el tiempo que operan. Por otra parte, la energía de las NPP de cada periodo es la suma de la energía producida en cada por cada una de las plantas nuevas y esta a su vez es función de su tipo, capacidad y localización.

$$DEM_t = \sum_{ep} IC_{ep} wkt_{ep,t} + \sum_{npp} \sum_{ct} ef_{npp,ct,t} \quad \forall t \in T \quad (5.1)$$

Energía producida por las EPP

La energía total que se genera en las plantas de potencia existentes es la suma de la energía generada en cada periodo por cada una de las plantas que integran el sistema. Como se mencionó antes la energía de las plantas individuales se calcula en función de la capacidad instalada y del tiempo que opera.

$$epf = \sum_t \sum_{ep} IC_{ep} wkt_{ep,t} \quad (5.2)$$

Cada planta trabaja a diferentes niveles de capacidad a lo largo del año, esto es una función del factor de planta de cada tecnología, por lo tanto, el tiempo disponible debe ser menor que un límite máximo conocido para cada tecnología ($DISP_{epp,t}$).

$$wkt_{epp,t} \leq DISP_{epp,t} \quad \forall epp \in EPP, \forall t \in T \quad (5.3)$$

De igual forma, las plantas existentes no pueden operar por debajo de una fracción conocida de su capacidad (χ_{epp}) para evitar paros de operación [142].

$$wkt_{epp,t} \geq \chi_{epp} DISP_{epp,t} \quad \forall epp \in EPP, \forall t \in T \quad (5.4)$$

Energía producida por las NPP

La energía que producen las nuevas plantas renovables es la suma de la energía que genera cada planta instalada en las diferentes localizaciones en cada periodo.

$$npof = \sum_{npp} \sum_{ct} \sum_t ef_{npp,ct,t} \quad (5.5)$$

El flujo individual de cada tecnología en un periodo determinado y de un sitio en particular se puede calcular el tiempo disponible para la operación de las nuevas plantas ($DISP_{npp,ct,t}$), el cual depende del factor de planta de cada tecnología y de la capacidad usada ($uc_{npp,ct,t}$) de cada tecnología para satisfacer la demanda que varía en cada periodo.

$$ef_{npp,ct,t} = DISP_{npp,ct,t} uc_{npp,ct,t} \quad \forall npp \in NPP, \forall ct \in CT, \forall t \in T \quad (5.6)$$

Para asegurar que las nuevas plantas trabajen de forma continua se añaden restricciones que garanticen que al menos una fracción (χ_{npp}) de la capacidad nominal de las nuevas plantas ($ic_{npp,ct}$) de be ser usado en cada periodo para cumplir con el régimen de operación mínimo [142]. Esta restricción se formula de la siguiente manera para evitar términos bilineales.

$$ef_{npp,ct,t} \geq \chi_{npp} DISP_{npp,ct,t} ic_{npp,ct} \quad \forall npp \in NPP, \forall ct \in CT, \forall t \in T \quad (5.7)$$

Los valores de estas fracciones depende de cada tecnología y fueron tomados de la literatura [157].

Consumo de agua

Las plantas de potencia requieren agua para operar y la intensidad con la que se usa este recurso depende de muchos factores como el tipo de tecnología [158] y las características del lugar como la temperatura, presión y humedad [159]. Este consumo de agua ($epwc_{eppp,t}$ y $npwc_{npp,ct,t}$) se puede calcular en función de la energía que se produce en las plantas existentes y en las nuevas como se muestra en las ecuaciones (5.8) y (5.9), respectivamente.

$$epwc_{eppp,t} = WC_{eppp} IC_{eppp} wkt_{eppp,t} \quad \forall epp \in EPP, \forall t \in T \quad (5.8)$$

$$npwc_{npp,ct,t} = WC_{npp,ct} ef_{npp,ct,t} \quad \forall npp \in NPP, \forall ct \in CT, \forall t \in T \quad (5.9)$$

El consume total por la generación de electricidad se calcula sumando el agua que consume cada tecnología en cada lugar y en cada periodo, tomando en cuenta tanto las plantas existentes como las que se instalan:

$$twc = \sum_{npp} \sum_t \sum_{ct} npwc_{npp,ct,t} + \sum_{eppp} \sum_t epwc_{eppp,t} \quad (5.10)$$

Emisiones de gases de efecto invernadero

Todas las plantas generan gases de efecto invernadero de forma directa (consumo de combustible) o indirecta (en su manufactura) que pueden ser cuantificados en toneladas de bióxido de carbono equivalente usando factores reportados (GHG_{eppp} y GHG_{npp}) [160]. Los gases de efecto invernadero que provienen de las plantas existentes ($epghg_{eppp,t}$) son una función de la capacidad instalada y el tiempo que trabajan y las emisiones de las plantas nuevas ($npghg_{npp,ct,t}$) están en función de la energía que generan ($ef_{npp,ct,t}$):

$$epghg_{eppp,t} = GHG_{eppp} IC_{eppp} wkt_{eppp,t} \quad \forall epp \in EPP, \forall t \in T \quad (5.11)$$

$$npghg_{npp,ct,t} = GHG_{npp} ef_{npp,ct,t} \quad \forall npp \in NPP, \forall ct \in CT, \forall t \in T \quad (5.12)$$

Las emisiones totales por la producción de electricidad se pueden calcular sumando los términos resultantes de las ecuaciones (5.11) y (5.12) como se muestra a continuación:

$$tghg = \sum_t \sum_{npp} \sum_{ct} npghg_{npp,ct,t} + \sum_t \sum_{eppp} epghg_{eppp,t} + traghg \quad (5.13)$$

Plantas de potencia renovables

En este modelo, se plantea el uso de 4 tecnologías de para la generación de potencia como potencial reemplazo de las plantas desmanteladas. Se considera la combustión directa de biomasa, la solar fotovoltaica, la concentración solar y las turbinas eólicas. $NPP = \{NBM, NPV, NCS, NEO\}$. El objetivo del modelo es seleccionar la mejor tecnología, capacidad y localización considerando factores económicos y ambientales. Estas características se definen en las siguientes secciones:

Capacidad instalada

Es posible instalar simultáneamente varias tecnologías en un mismo sitio (CT). Cada lugar tiene una capacidad mínima ($CMIN^{npp}$) y máxima ($CMAX^{npp}$) que se puede instalar y ésta varía con cada tecnología, por lo tanto la capacidad instalada que se seleccione ($ic_{npp,ct}$) para cada planta debe de estar entre estos valores. Esta capacidad de las plantas (ic) es una variable de decisión que debe ser mayor que la capacidad usada (uc) en cada periodo de tiempo como se muestra en las ecuaciones (5.21), (5.27), (5.30) y (5.34). También, es posible que una localización no se instale ninguna planta, por lo que se usan variables binarias (y_{ct}^{npp}) para modelar la existencia o ausencia de cada planta.

$$y_{ct}^{npp} CMIN^{npp} \leq ic_{npp,ct} \quad \forall npp \in NPP, \forall ct \in CT \quad (5.14)$$

$$y_{ct}^{npp} CMAX^{npp} \geq ic_{npp,ct} \quad \forall npp \in NPP, \forall ct \in CT \quad (5.15)$$

Costos de capital

El costo de capital se calcula en función de la capacidad instalada usando parámetros reportados en la literatura (CIC_{npp}) [161]. El costo total de inversión se calcula sumando los costos de capital de las plantas instaladas en las diferentes ciudades usando la ecuación (17)

$$capcost_{npp,ct} = ic_{npp,ct} CIC_{npp} \quad \forall npp \in NPP, \forall ct \in CT \quad (5.16)$$

$$tcapcost_{npp} = \sum_{ct} capcost_{npp,ct} \quad \forall npp \in NPP \quad (5.17)$$

Costos de operación y mantenimiento

Los costos de operación y mantenimiento ($onmcost_{npp,ct}$) se calculan en función de la electricidad producida por las nuevas plantas renovables que se instalen [162] usando constantes y para calcular el costo total de operación y mantenimiento de cada tecnología ($tonmcost_{npp}$) es necesario sumar el correspondiente a cada sitio:

$$onmcost_{npp,ct} = \sum_t ef_{npp,ct,t} OM_{npp} \quad \forall npp \in NPP, \forall ct \in CT \quad (5.18)$$

$$tonmcost_{npp} = \sum_{ct} onmcost_{npp,ct} \quad \forall npp \in NPP \quad (5.19)$$

Generación de electricidad

Las diferentes tecnologías renovables seleccionadas en este estudio no se pueden modelar de la misma manera en cada aspecto, una de las principales diferencias es como se aprovecha la fuente energética para generar electricidad con las diferentes tecnologías como se muestra a continuación:

Plantas de biomasa

La biomasa se quema para producir electricidad a través de una turbina de vapor. La electricidad que se genera en cada periodo depende de la cantidad de biomasa que se consume, ($tbmc_{ct,brm,t}$), el contenido energético de la biomasa (LHV_{brm}) y la eficiencia de la planta (η_{nbm}), pero la cantidad de electricidad está limitada por el factor de planta que se considera a través del tiempo disponible ($DISP_{nbm,ct,t}$) y la capacidad que se usa ($uc_{nbm,ct,t}$).

$$\eta_{nbm} \sum_{brm} (tbmc_{ct,brm,t} LHV_{brm}) = DISP_{nbm,ct,t} uc_{nbm,ct,t} \quad \forall nbm \in NBM, \forall ct \in CT, \forall t \in T \quad (5.20)$$

Para seleccionar la capacidad de las plantas de biomasa, la capacidad instalada ($ic_{nbm,ct}$) debe ser mayor que la capacidad usada ($uc_{nbm,ct,t}$) en cada periodo de tiempo (t) con la finalidad de que se pueda satisfacer la demanda requerida en cada uno de estos periodos.

$$ic_{nbm,ct} \geq uc_{nbm,ct,t} \quad \forall nbm \in NBM, \forall ct \in CT, \forall t \in T \quad (5.21)$$

Es evidente que existe una cantidad finita de biomasa para la producción de electricidad por lo que la biomasa que se consume en las plantas debe de estar por debajo de este límite como se muestra a continuación.

$$\sum_{ct} bmc_{bp,ct,brm,t} \leq AVBM_{bp,brm,t} \quad \forall bp \in BP, \forall brm \in BRM, \forall t \in T \quad (5.22)$$

En caso de ser necesario (y conveniente) se considera la posibilidad de transportar biomasa desde los diferentes puntos para enviarla a las diferentes plantas en caso de que se instalen. El costo que implica transportar la biomasa ($tracost$) se calcula en función del peso de recurso transportado usando el parámetro $UTC_{ct,bp}$ (EUR/ton) [163] en la ecuación (5.23). De forma similar se calculan las emisiones asociadas al transporte de la biomasa ($traghg$) usando el parámetro $UTE_{ct,bp}$ (tCO₂/ton) [164] en la ecuación (5.24). Los parámetros anteriores se calculan en función de la distancia que existe entre los productores y consumidores. El cálculo de estas distancias se realizó como se muestra en la Ref. [165].

$$tracost = \sum_{brm} \sum_{bp} \sum_{ct} \sum_t (UTC_{ct,bp} bmc_{bp,ct,brm,t}) \quad (5.23)$$

$$traghg = \sum_{brm} \sum_{bp} \sum_{ct} \sum_t (UTE_{ct,bp} bmc_{bp,ct,brm,t}) \quad (5.24)$$

La biomasa que se consume en una planta instalada de biomasa en el sitio CT es la suma de la biomasa que todos los productores BP le envía.

$$tbmc_{ct,brm,t} = \sum_{bp} (bmc_{bp,ct,brm,t}) \quad \forall ct \in CT, \forall brm \in BRM, \forall t \in T \quad (5.25)$$

Plantas solares fotovoltaicas

La energía que producen las plantas de paneles fotovoltaicos ($ef_{npv,ct,t}$) dependen de su área ($ua_{npv,t}$), del recurso solar que dispongan ($DSI_{ct,t}$) y de la eficiencia de la tecnología (η_{npv}). Por tanto, cada potencial sitio de instalación cuenta con un recurso solar diferente que hace que hace más factibles a unos sitios que a otros.

$$ef_{npv,ct,t} = \eta_{npv} DSI_{ct,t} ua_{npv,ct,t} \quad \forall npv \in NPV, \forall ct \in CT, \forall t \in T \quad (5.26)$$

Es importante mencionar que esta tecnología no opera las 24 horas del día. Esta limitación técnica se considera en el modelo usando periodos de día y noche, es decir, $ef_{npv,ct,t}$ será cero durante los periodos de noche. Consecuentemente, esta tecnología no puede contribuir a satisfacer la demanda nocturna de electricidad.

La capacidad instalada de las plantas fotovoltaicas debe ser mayor que la requerida en cada periodo. Esto está directamente relacionado con el área.

$$ic_{npv,ct} \geq uc_{npv,ct,t} \quad \forall npv \in NPV, \forall ct \in CT, \forall t \in T \quad (5.27)$$

$$ia_{npv,ct} \geq ua_{npv,ct,t} \quad \forall npv \in NPV, \forall ct \in CT, \forall t \in T \quad (5.28)$$

Centrales térmicas solares

En este caso la energía del sol se concentra en un solo punto para calentar un fluido y generar vapor para generar electricidad. La cantidad de energía que se logra producir ($ef_{ncs,ct,t}$) depende del área del heliostato usado ($ua_{ncs,t}$), la irradiación solar ($DSI_{ct,t}$) y la eficiencia del proceso (η_{ncs}). Como se mencionó en la sección anterior cada sitio potencial de instalación tiene un recurso solar diferente y los sitios con mejor recurso solar requieren menos área para producir una determinada cantidad de energía.

$$ef_{ncs,ct,t} = \eta_{ncs} DSI_{ct,t} ua_{ncs,ct,t} \quad \forall ncs \in NCS, \forall ct \in CT, \forall t \in T \quad (5.29)$$

A diferencia de los paneles fotovoltaicos esta tecnología se puede acoplar con un almacenamiento térmico de energía que incrementa el factor de planta y permitiéndole operar en los periodos de día y noche.

De igual forma que para las tecnologías anteriores la capacidad instalada y el área de las centrales térmicas debe ser mayor que las usadas en cada periodo.

$$ic_{ncs,ct} \geq uc_{ncs,ct,t} \quad \forall ncs \in NCS, \forall ct \in CT, \forall t \in T \quad (5.30)$$

$$ia_{ncs,ct} \geq ua_{ncs,ct,t} \quad \forall ncs \in NCS, \forall ct \in CT, \forall t \in T \quad (5.31)$$

Como se presentó en las ecuaciones (5.26) y (5.29), la capacidad de las tecnologías solares depende del área, pero el área que se puede destinar a la producción de electricidad es limitada por lo que en el modelo se incluye una restricción que considera la cantidad de área disponible que debe ser mayor o igual que el área usada por las plantas solares.

$$ia_{npv,ct} + ia_{ncs,ct} \leq AD_{ct} \quad \forall ct \in CT \quad (5.32)$$

Plantas eólicas

La electricidad que se genera en las plantas eólicas ($ef_{neo,ct,t}$) depende de la densidad de potencia del viento de cada lugar ($WPD_{ct,t}$), la eficiencia de las turbinas (η_{neo}), el área de barrido de las turbinas (SA) y el número de turbinas utilizadas ($ut_{ct,t}$).

$$uc_{neo,ct,t} = \eta_{neo} WPD_{ct,t} (ut_{ct,t} SA) \quad \forall neo \in NEO, \forall ct \in CT, \forall t \in T \quad (5.33)$$

La capacidad instalada y el área (en este caso el área se refiere al área del círculo que crean las aspas de la turbina al girar) debe mayor que la utilizada en cada periodo.

$$ic_{neo,ct} \geq uc_{neo,ct,t} \quad \forall neo \in NEO, \forall ct \in CT, \forall t \in T \quad (5.34)$$

$$ia_{neo,ct} \geq ua_{neo,ct,t} \quad \forall neo \in NEO, \forall ct \in CT, \forall t \in T \quad (5.35)$$

Costo total anual

Uno de los principales objetivos de la transición energética es minimizar el costo relacionado a la instalación de nuevas tecnologías y a la operación del sistema. Así, el costo anual total se calcula tomando en cuenta el costo de capital anualizado de las nuevas plantas instaladas, los costos de operación de las plantas nuevas y las existentes y los costos de transporte de la biomasa.

$$tcost = \sum_{npp} CRF_{npp} tcapcost_{npp} + \sum_{npp} tonmcost_{npp} + \sum_{ep} tonmcost_{ep} + tracost \quad (5.36)$$

Aproximación multiobjetivo

Un sistema sustentable requiere tomar en cuenta aspectos que van más allá del factor económico. En este caso se busca minimizar el costo anual total, el consumo de agua y las emisiones de gases de efecto invernadero. Para lograrlo se usa una función multiobjetivo normalizada como la que se muestra a continuación:

$$\min mof = \varphi_{tcost} + \varphi_{twc} + \varphi_{tghg} \quad (5.37)$$

La normalización de los objetivos se logra utilizando el punto utópico y el punto de Nadir, como se presenta en las siguientes ecuaciones:

$$\varphi_{tcost} = \frac{tcost - \Phi_c^{\min}}{\Phi_c^{\max} - \Phi_c^{\min}} \quad (5.38)$$

$$\varphi_{twc} = \frac{twc - \Phi_w^{\min}}{\Phi_w^{\max} - \Phi_w^{\min}} \quad (5.39)$$

$$\varphi_{tghg} = \frac{tghg - \Phi_g^{\min}}{\Phi_g^{\max} - \Phi_g^{\min}} \quad (5.40)$$

5.1.2 Caso de estudio

Se seleccionó el Sistema Eléctrico Peninsular de España (SEPE) como caso de estudio para mostrar la aplicación del modelo desarrollado. En él, se incluyen 47 de las 50 provincias de España y se consideran la demanda y la estructura de generación de estas. Algunos trabajos han analizado las características del SEPE estudiado la capacidad y diversidad de la

infraestructura, los recursos renovables disponibles y la distribución geográfica del sistema [166], además, se ha intentado predecir la demanda de electricidad [167] y se han estudiado el efecto de fuentes específicas de energía como la solar y eólica [168], [169]. Estos trabajos (entre otros) proveen información importante para resolver el modelo matemático presentado anteriormente y además fue necesario contribuir con datos nuevos para un mejor entendimiento y descripción del sistema durante la transición energética como se muestra a continuación.

Estructura de generación existente

La estructura de generación del SEPE está integrada por tecnologías como la hidroeléctrica convencional, hidroeléctrica con almacenamiento por bombeo, nuclear, térmica de carbón, ciclo combinado, eólica, solar fotovoltaica, solar térmica, cogeneración y térmica de desechos renovable y no renovables [170]. Sin embargo, en este caso de estudio se tomarán en cuenta únicamente las que contribuyen en mayor medida a satisfacer la demanda eléctrica, es decir, la hidroeléctrica (HY), nuclear (NU), térmica de carbón (CA), ciclo combinado (CC), eólica (EO), fotovoltaica (PV), térmica solar (CS) y cogeneración (CG). Para resolver el modelo de optimización se recopiló la información de las plantas de potencia mencionada como sus emisiones de GEI [171], costos de operación [161], capacidad y localización [172], etc. Adicionalmente, se calcularon otros parámetros usando la información disponible en la literatura como el consumo de agua de cada tecnología [158], [159] y el factor de planta como se muestra en los siguientes párrafos.

Plantas de potencia próximas a ser desmanteladas

La mayoría de los sistemas de electricidad al rededor del mundo requieren sustituir parte de su infraestructura para lograr disminuir sus emisiones y alcanzar las metas del acuerdo de Paris. En el caso del SEPE, se requiere que las plantas que operan con carbón cierren debido a su alto impacto en el calentamiento global. El SEPE reportó en 2019 una capacidad instalada de plantas de potencia a base de carbón de 9,215 MW que contribuyó, a lo largo de ese mismo año, para cubrir entre el 1.6% y el 13.1% de la demanda de electricidad. Por otra parte, el SEPE perderá próximamente sus centrales nucleares (7,117 MW) debido al que su

tiempo de vida útil se acerca a su fin. Estas centrales nucleares contribuyen con más del 20% de la electricidad que produce el SEPE (22.6% en 2019) y tiene factores de planta de alrededor de 90% todo el año. Ambas tecnologías dan robustez a la estructura de generación actual porque no dependen de fuentes inciertas como la radiación solar y la velocidad del viento. En este trabajo se busca sustituir 16,332 MW (carbón y nuclear) con plantas renovables nuevas, que ofrezcan la misma solidez a la estructura de generación.

Plantas de potencia nuevas

La variedad de opciones para la generación de energía renovable ha crecido y se ha diversificado en los últimos años, desafortunadamente, pocas son las tecnologías que se comercializan para proyectos de generación eléctrica a gran escala. En este caso de estudio se consideran cuatro tecnologías para la producción de electricidad: plantas de quema directa de biomasa (NBM), centrales fotovoltaicas (NPV), centrales solares de torre central con almacenamiento térmico (NCS) y plantas eólicas (NEO). De las tecnologías mencionadas, se seleccionará la mejor o las mejores para cada lugar y se determinará su capacidad óptima considerando el costo y los beneficios ambientales. Para esto es necesario tomar en cuenta los recursos energéticos de cada provincia ya que todas tienen diferente disponibilidad de biomasa [173], recurso solar [174] y potencia eólica [175] por lo que esta información se recolecta de reportes y artículos para usarse en el modelo propuesto.

Factor de planta

Los sistemas eléctricos nacionales son bastante complejos y es difícil que todas las tecnologías que los integran operen a toda su capacidad todo el tiempo debido a mantenimiento, situaciones anormales y/o fluctuaciones en la demanda de electricidad o disponibilidad de las fuentes de energía. Para seleccionar una combinación adecuada de tecnologías renovables que pueda sustituir a las tecnologías basadas en carbón y en energía nuclear es importante considerar sus limitaciones. El factor de planta (CF) puede ser de gran ayuda para considerar las limitaciones y la variabilidad en la generación de electricidad para tecnologías renovables y no renovables. El CF es la relación entre la energía que se genera en un periodo determinado de tiempo y la máxima cantidad que se podría producir en ese

periodo de tiempo. En este caso de estudio se calculó el CF mensual de cada tecnología usando información de la Red Eléctrica de España (REE) del 2014 al 2019 [170] usando la ecuación (5.41).

$$CF = \frac{\text{Actual Energy Generated}}{(\text{Installed Capacity})(\text{time})} \quad (5.41)$$




Figura 5.2: Factor de planta promedio de las diferentes tecnologías que integran el SEPE (2014 – 2019)

Se calculo el CF promedio de cada mes y los resultados se muestran en la Fig. 5.2 Además, si se supone que se opera a Máxima capacidad, es posible calcular el tiempo de trabajo disponible a partir de la energía real generada. Indirectamente, este parámetro se usa, junto con la capacidad instalada, como límite superior en el flujo de energía producido por cada tecnología (ecuaciones 5.3 y 5.6) y ayuda a considerar la disponibilidad de recursos en las plantas de energía existentes y nuevas (biomasa y energía eólica). En el caso de las tecnologías solares, las horas de sol de cada provincia se utilizaron para calcular el tiempo de trabajo disponible.

Dióxido de carbono equivalente y consumo de agua

El sector energético es uno de los principales responsables de la generación de emisiones de gases de efecto invernadero [160] y al mismo tiempo es uno de los principales consumidores

de agua fresca [153]. Por lo tanto, en este trabajo se considera ambos rubros en la toma de decisiones. Las emisiones directas y de ciclo de vida se usan para cuantificar las toneladas de dióxido de carbono equivalente en función de la energía que se genera utilizando los factores reportados y calculados que se muestran en la Tabla 5.1.

Tabla 5.1. Dióxido de carbono equivalente generado por cada tecnología.

Tecnología	gCO₂eq/kWh	Referencia
Ciclo combinado	370	Calculado [176]
Carbón	960	Calculado [176]
Cogeneración	370	Calculado [176]
Nuclear	12	Reportado [177]
Hidroeléctrica	24	Reportado [177]
Eólica	11	Reportado [177]
Solar fotovoltaica	48	Reportado [177]
Solar térmica	27	Reportado [177]
Biomasa	230	Reportado [177]

El consumo de agua depende tanto del tipo de tecnología como de las características del lugar donde se instale la planta como presión, temperatura y humedad. En este caso, el consumo de agua de las tecnologías basadas en la generación de vapor para producir electricidad como ciclo combinado, carbón, cogeneración, nuclear, concentración solar y biomasa se calculó usando las correlaciones reportadas en la Ref. [159], ya que toman en cuenta condiciones climáticas y geográficas de los lugares donde se puede instalar una planta nueva. El consumo de agua de tecnologías como la hidroeléctrica, eólica y fotovoltaica se calculó usando los parámetros de la Ref. [158].

Área disponible

Las plantas solares requieren una gran cantidad de área para la generación de electricidad. Por ejemplo, la planta fotovoltaica Núñez de Balboa tendrá una producción anual de 832

GWh , pero requiere 1,000 hectáreas en tres municipalidades de Extremadura, España [178]. Para este caso de estudio, el área disponible para la instalación de NPV y NCS está limitada al 1% del área total de cada provincia.

Demanda de electricidad

La demanda de electricidad (ED) cambia cada mes como se muestra en la Fig. 5.4, además, cambia constantemente durante el día como se muestra en la Fig. 5.3, pero discretizar el tiempo en periodos muy cortos incrementaría el tiempo de cómputo. Para resolver el problema utilizando un numero pequeño de periodos, pero considerando la variación de la demanda durante el día se dividió cada día en dos periodos de 08:00 a 20:00 para la demanda diurna y de 20:00 a 08:00 para la demanda nocturna (ver Fig. 5.4). Después de evaluar la demanda en estos intervalos de tiempo para diferentes días del año el porcentaje promedio de la demanda de electricidad durante el día es del 54% y 46% durante la noche. Usando la demanda mensual promedio de 6 años (ver Fig. 5.3) y ponderando la demanda en día y noche con el porcentaje anterior se calcula la demanda de cada periodo que se muestra en la Fig. 5.5. Entonces, el problema se discretiza en 24 periodos. Existen 12 periodos que representan la demanda mensual durante el día (08:00 a 20:00) y 12 periodos que representan la demanda mensual durante la noche (20:00 a 08:00). De esta manera se toma en cuenta la variación de la electricidad en un numero de periodos manejable.




Figura 5.3: Demanda mensual de electricidad en el SEPE para diferentes años (2014 – 2019) [170].

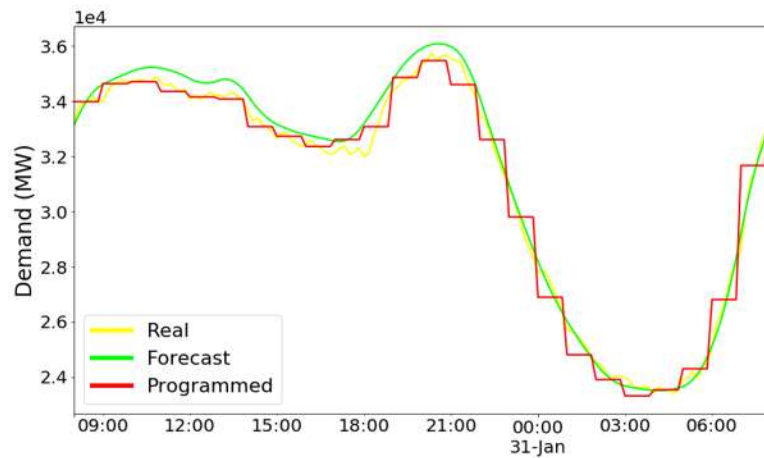


Figura 5.4: Ejemplo del seguimiento de la demanda de electricidad en el SEPE, Enero 30–31, 2020 [179].




Figura 5.5: Discretización de la demanda en periodos de día y de noche.

5.1.3 Resultados

El modelo mixto entero líneas fue codificado en el lenguaje de modelado matemático GAMS [12]. Este modelo se compone de 195,261 variables continuas, 141 variables binarias y 72,359 restricciones. En una primera etapa se resolvió el modelo usando una función mono objetivo (es decir, se minimizan twc , $tghg$ y $tcost$, independientemente) para encontrar los

limites superiores e inferiores de la función multiobjetivo, Ec. (5.40). después, la función multiobjetivo se usa para minimizar el consumo de agua, las emisiones y el costo anual total. En esta sección se presentan los resultados de 4 escenarios diferentes. Primero se presenta el caso base que se refiere a la estructura de generación actual y se comparan los resultados que se obtienen con el modelo propuesto contra los datos reales del SEPE. Después se muestran los resultados de la sustitución óptima de las plantas desmanteladas considerando únicamente la minimización del costo anual total como función objetivo y se compara con los resultados que se obtienen al resolver el mismo modelo utilizando la función multiobjetivo. Finalmente, se estudia el efecto de la inversión económica en la disminución de emisiones y de consumo de agua.

Sistema actual

La estructura de generación actual (es decir, las plantas que se encuentran en operación actualmente) se calculó utilizando el modelo matemático presentado previamente y los resultados se compara con la información reportada de la generación de electricidad para el año 2019 del SEPE (Fig. 5.6b). La Fig. 5.6a muestra la estructura de generación de electricidad que minimiza simultáneamente el costo, el consumo de agua y las emisiones. Si se comparan ambas estructuras de generación se observa que el modelo es capaz de representar la tendencia en la estructura de generación mes con mes. Los meses de noviembre y diciembre son los periodos donde existe la mayor diferencia entre ambas gráficas, específicamente para la hidroeléctrica, eólica nuclear y de ciclo combinada. En el caso real existe una mayor contribución de hidroeléctrica y eólica que en el calculado debido a la variabilidad de la velocidad del viento y a al cambio en los niveles de los embalses. Sin embargo, las tecnologías de ciclo combinado, carbón y nuclear proveen de flexibilidad al sistema. Es importante recordar que los factores de planta que se usaron en el modelo fueron resultado de la información promedio de 6 años (2014 – 2019) y el factor de planta de las plantas eólicas en noviembre y diciembre de 2019 son los valores más altos para estos meses del conjunto de datos. Otra diferencia que se puede encontrar es que la solución óptima del modelo propuesto reduce la operación de las plantas de carbón casi hasta su mínimo valor posible en todos los periodos. No obstante, los datos del sistema real muestran que entre 2014 y 2018 el carbón tenía una participación importante en la generación de electricidad y fue

hasta febrero de 2019 que se su participación disminuyo debido a los compromisos adquiridos por España en la lucha contra el cambio climático.

En este caso no se considera la incertidumbre en las fuentes renovables, pero se asume que la flexibilidad que tiene el sistema puede manejar sus fluctuaciones.

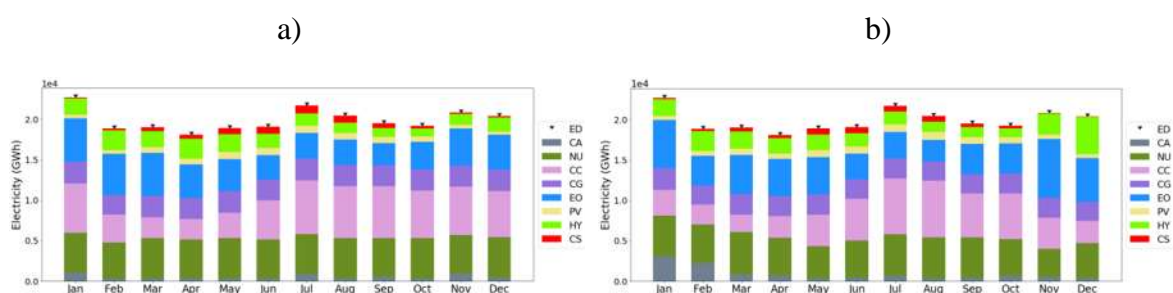


Figura 5.6: a) Estructura de generación óptima utilizando la función multiobjetivo propuesta. b) Estructura de generación del SEPE en 2019 (elaborada con información de la REE [170]).

Tabla 5.2: Resumen de los resultados económicos y ambientales.

Variable (unidades)	Sistema actual	Transición Min TAC	Transición Min MO	TAC trade-off Min MO-A	TAC trade-off Min MO-B
GHG (MtCO₂eq/año)	47.647	36.838	23.975	26.702	32.392
Agua (hm³/año)	303.766	253.09	189.856	199.347	195.974
tCO₂eq/MWh	0.19	0.15	0.10	0.11	0.13
L/MWh	1,218	1,015	761	799	786
TAC (MEUR/año)	12,360.01	22,133.31	27,325.67	25,594.88	23,864.1
Costo capital (MEUR)	-	71,716.56	136,052.5	114,603.6	95,455.0
efep (TWh/año)	249.3	154.2	117.3	118.5	131.1
efnp (TWh/año)	-	95.2	132.1	130.9	118.2
Renovables (TWh/año)	141.2	175.0	199.7	198.2	187.5
No renovables (TWh/año)	108.1	74.3	49.7	51.2	61.8

Transición energética: minimización del costo anual total

En esta sección se presenta la combinación óptima de tecnologías que pueden sustituir a las plantas nucleares y de carbón minimizando únicamente el costo anual total. Hasta este punto no se consideran ni las emisiones ni el consumo de agua en la toma de decisiones. Se usó toda la información mostrada en la sección del caso de estudio. Los resultados brindan la combinación óptima de tecnologías nuevas y existentes para satisfacer la demanda de electricidad en un año, así como la localización y capacidad necesaria de las plantas renovables nuevas. La Fig. 5.7 presenta cuatro mapas de España peninsular, cada mapa está dividido en las 47 provincias y la coloración indica la localización y la capacidad de las nuevas plantas de potencia incluyendo NBM (biomasa), NCS (concentración solar), NPV (solar fotovoltaica) y NEO (eólica). Los resultados muestran que las plantas de potencia NBM se instalan cerca de los mayores productores de biomasa para evitar en la medida de lo posible los costos de transporte. El sur de España tiene un gran recurso solar disponible, por lo que las tecnologías NPV y NCS se instalan principalmente en esta región. En el caso de las turbinas de viento se instalan en las zonas con mayor velocidad de viento (Girona, Almería y Cádiz). La Fig. 5.8 muestra la estructura de generación del nuevo sistema. La energía solar fotovoltaica es la que contribuye en mayor medida a en la sustitución de las plantas desmanteladas; sin embargo, el sistema es altamente dependiente de las otras tecnologías por la limitación de las plantas solares de trabajar únicamente durante el día. En este sentido las plantas de cogeneración y principalmente las de ciclo combinado tienen un papel fundamental para satisfacer la demanda en los meses en los que disminuye el recurso solar. Los costos, el consumo de agua y las emisiones generadas por este sistema se presentan en la Tabla 5.2. El sistema actual tiene un consumo de 1,218 L/MWh y genera 0.19 tCO₂eq/MWh. Utilizando el modelo propuesto para minimizar el costo de la transición energética (sustituyendo las plantas nucleares y de carbón) se logra disminuir el consumo de agua 16.7% y las emisiones de gases de efecto invernadero caen 21.0% (Nota, los resultados del sistema actual en la Tabla 5.2 se calcularon usando la demanda de la Fig. 5.5, y es diferente a la utilizada para obtener la Fig. 5.6).

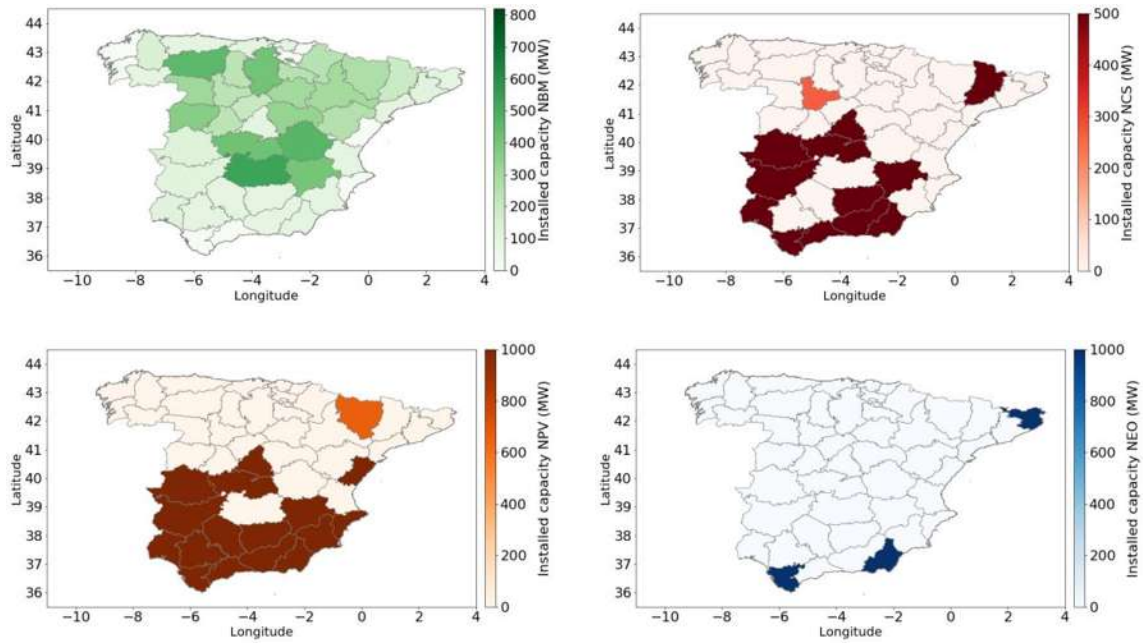


Figura 5.7: Localización y capacidades requeridas de las nuevas plantas de energía renovable. minimización del costo anual total.




Figura 5.8: Estructura de generación del SEPE. Minimización del costo anual total.

Transición energética: minimización de la función multiobjetivo

Es este escenario se presenta la combinación óptima de tecnologías renovables para sustituir a las plantas de carbón y nucleares que se obtiene minimizando simultáneamente los tres objetivos planteados en la ecuación (5.37). En este escenario se establece que los tres

objetivos planteados tienen la misma prioridad; sin embargo, utilizando el mismo modelo planteado se puede priorizar cualquiera de ellos y analizar su efecto en la toma de decisiones. La Fig. 5.9 presenta la localización óptima de las tecnologías renovables requeridas. Se observa que ninguna planta de biomasa se instala en este escenario y la instalación de las plantas eólicas y solares crece considerablemente.

Si se compara la capacidad requerida de las nuevas plantas que se muestra en la Fig. 5.9 con la capacidad instalada entre las plantas de carbón y nucleares (16,332 MM) es evidente la gran diferencia. Las plantas fotovoltaicas solo pueden generar energía durante el día por lo que toda esta infraestructura queda inservible durante la noche. Los concentradores solares con almacenamiento se instalan casi en todo el territorio, dejando fuera únicamente a las provincias del norte con el peor recurso solar. Es importante recordar que para este caso de estudio se toma un solo punto de instalación por provincia y la capacidad máxima está limitada por un límite de capacidad máxima y por el área disponible en cada provincia, es por ello por lo que las plantas se distribuyen por todo el territorio, incluso fuera de las provincias con mejor recurso solar. Las turbinas de viento se instalan de forma extensiva debido a que presentan la menor generación de emisiones y el menor consumo de agua. Se estableció un número máximo de 450 turbinas de viento instaladas por provincia. Cuando el límite se alcanza en un sitio es necesario seleccionar una provincia diferente, incluso si el recurso eólico no es tan bueno como se desearía. En este caso, se instaló esta tecnología extensivamente porque ayuda a minimizar las emisiones y el consumo de agua, pero muchos sitios no aprovechan su capacidad instalada por el limitado recurso eólico y es necesario un sobredimensionamiento que se traducen en sistemas muy costosos. El límite que se propuso está basado en valores de plantas existentes pero la solución se podría mejorar usando el mismo modelo acoplado con información que indique solamente sitios específicos, donde es factible instalar turbinas de viento junto con características particulares como el número máximo que la geografía de cada provincia permite. En la Tabla 2 se comparan los resultados del modelo cuando se minimiza el costo anual total (min TAC) contra la solución de la formulación multiobjetivo (MO) y se observa que para la solución multiobjetivo el consumo de agua y las emisiones de gases de efecto invernadero disminuyen 24.98% y 34.92, respectivamente, pero el TAC se incrementa 23.46%. Por otro lado, cuando se compara la

solución multiobjetivo con el sistema actual se nota que es posible reducir el consumo de agua fresca y las emisiones 37.5% y 49.7%, respectivamente.

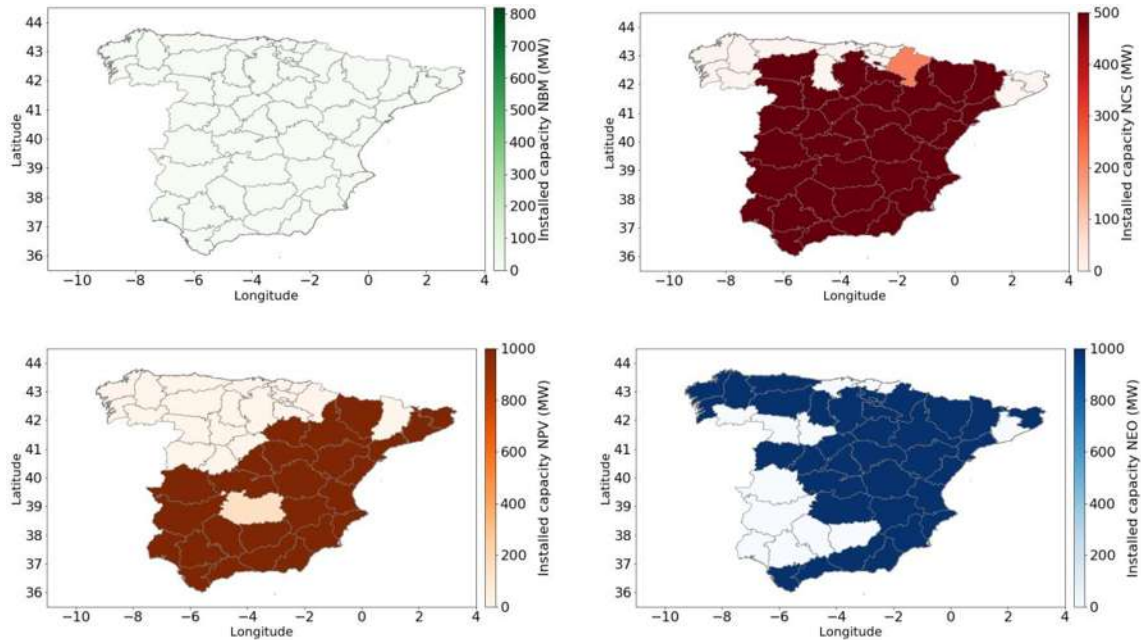


Figura 5.9: Capacidad requerida y localización de las energías renovables. Minimización de la función multiobjetivo.

La estructura de generación se presenta en la Fig. 5.10, donde se observa que además de reemplazar con éxito las plantas de carbón y nucleares, la participación del ciclo combinado y de la cogeneración disminuye. A lo largo del año se logra producir 70.2% de la energía total con renovables. Las plantas existentes generan 47.03% de la demanda anual y las nuevas plantas generan 52.97%.




Figura 5.10: Estructura de generación del SEPE. Minimización de la función multiobjetivo.

Transición energética: análisis del efecto de la inversión

Como se mencionó anteriormente, para disminuir el consumo de agua y las emisiones de gases de efecto invernadero, la solución multiobjetivo requiere un incremento del 23.46% con respecto a la solución que minimiza el costo anual total. El utilizar la función multiobjetivo permite realizar un Pareto entre los objetivos. Por ejemplo, se puede explorar el comportamiento del sistema si se asignan diferentes niveles de prioridad a cada objetivo o se pueden investigar soluciones intermedias como se presenta a continuación.

En esta sección se analizaron dos soluciones intermedias (subóptimas) para el caso del costo anual total, estas soluciones se fijaron entre la solución del caso donde se minimiza únicamente el TAC (22,133.31 MEUR/año) y la solución multiobjetivo (27,325.67 MEUR/año). Los valores seleccionados fueron 25,594.88 MEUR/año (TRADE-off A) y 23,864.10 MEUR/año (TRADE off B) ya que son valores equidistantes. Los resultados de ambos casos se presentan en la Tabla 5.2 y la combinación y localización de la estructura de generación se presenta a continuación.

TRADE-off A

En este escenario se le asignó un límite superior de 25,594.88 MEUR/año al TAC. Como se muestra en la Fig. 5.11, la biomasa se empieza a volver una opción atractiva para abaratar el costo ya que se disminuye el sobredimensionamiento de la tecnología eólica instalada gracias

a su factor de planta y a que las plantas de biomasa no están sujetas a fuentes energéticas variantes como el viento. Sin embargo, las emisiones de gases de efecto invernadero y el consumo de agua se incrementan 10.21% y 4.76%, respectivamente, con respecto a la solución MO. Instalar 2,815 MW de NBM ayuda a reducir la capacidad instalada de NPV, NCS y NEO en 2.09%, 24.58% y 35.29%, respectivamente. La Fig. 5.12 muestra que la estructura de generación de las tecnologías existentes no varía, pero la biomasa sustituye principalmente a la generación eléctrica eólica y solar. Los resultados indican que esta solución es menos amigable con el ambiente, pero las plantas de biomasa le dan más flexibilidad al sistema que las tecnologías solares y eólica ya que reduce la incertidumbre asociada a fuentes intermitentes.

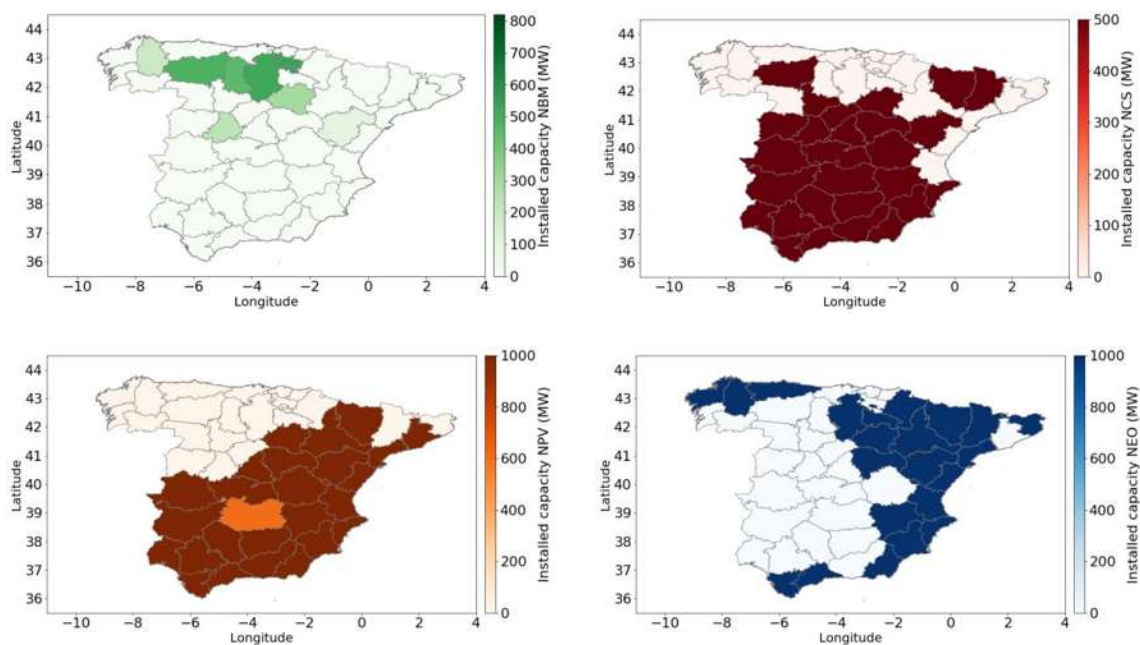


Figura 5.11: Capacidad requerida y localización de las energías renovables. TRADE-off A.




Figura 5.12: Estructura de generación del SEPE. Trade-off A.

Trade-off B

El límite superior del TAC en este caso se fijó en 23,864.10 MEUR/año, los resultados en la Fig. 5.13 y la Fig. 5.14 muestran que reducir el costo 12.67% requiere incrementar la capacidad instalada de biomasa mientras que la capacidad instalada de eólica y NCS caen considerablemente. Una capacidad instalada de 8,180 MW de biomasa reduce la capacidad instalada de NCS en 68.05% y la de NEO en 48.2%. Consecuentemente, las emisiones y el consumo de agua suben 21.31% y 3.22%, respectivamente.

Como se mostró anteriormente, el modelo que se propone da información útil para los tomadores de decisiones en la transición energética. Por ejemplo, este tipo de análisis puede ser útil cuando un país requiere alcanzar una meta específica de reducción de emisiones como los que firmaron el Acuerdo de París. Sin embargo, en trabajos futuros se debería considerar información adicional sobre la flexibilidad del sistema. Es decir, tiempos de arranque, costos de arranque y carga parcial.

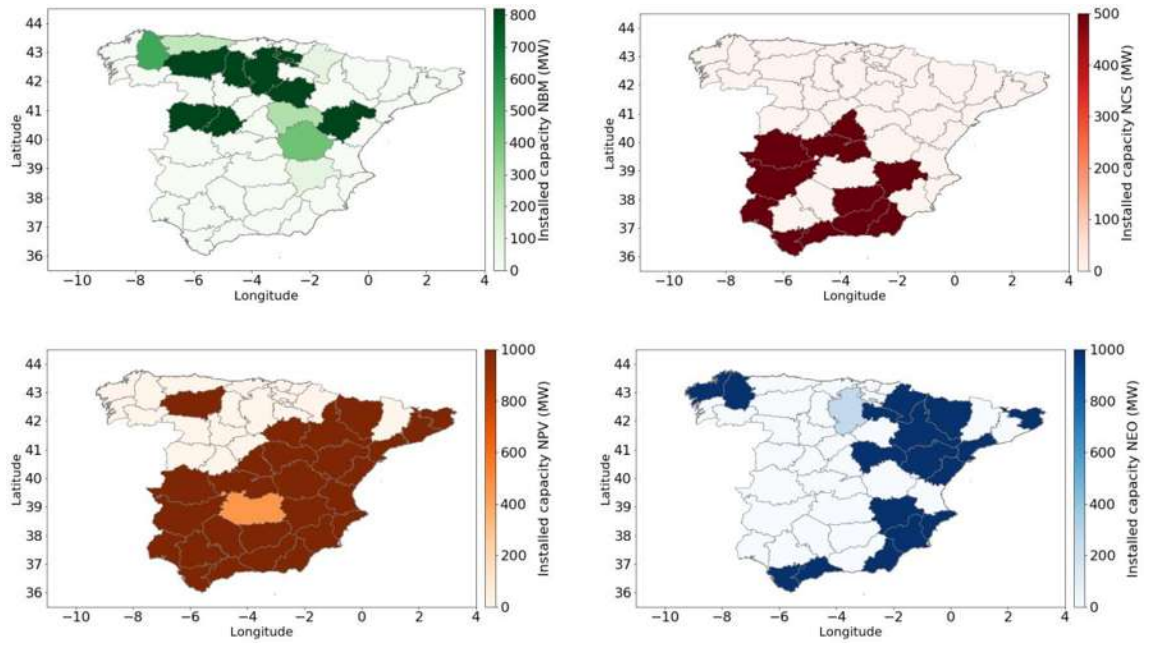


Figure 5.13: Capacidad requerida y localización de las energías renovables. Trade-off B.




Figure 5.14: Estructura de generación del SEPE. TRADE-off B.

Conclusiones

Diseño de antorchas

Se demostró cómo utilizar la técnica de MM para reformular un problema cuando se conoce la distribución resultante. También, se demostró cómo utilizar aproximaciones más conservadoras (CVaR y AS) que se pueden aplicar cuando la distribución resultante sea desconocida. El caso de estudio del diseño de la antorcha mostró que la aproximación SigVaR ofrece un desempeño superior a las alternativas más conservadoras y es una gran herramienta para los casos donde no se conoce la distribución resultante.

Análisis de precios de carbono en proyectos de mitigación de emisiones

El modelo que se presenta permite determinar el tamaño óptimo y las condiciones de operación de un sistema de cogeneración alimentado simultáneamente con gas natural y corrientes combustibles de desecho. Este modelo se aplicó a un caso de estudio para analizar el efecto que tiene la monetización de las emisiones en la factibilidad económica y en la disminución de emisiones, demostrando que la monetización no tiene el impacto que se esperaría ya que se requieren precios de emisiones muy elevados para tener un efecto significativo. El utilizar una solución compromiso como la que se presenta en este trabajo acerca la solución al punto utópico sin la necesidad de sacrificar ganancias para tener una disminución de emisiones del 85% comparado con la forma en la que tradicionalmente se lleva a cabo la eliminación de los GCD. En trabajos futuros se sugiere analizar el panorama de usar simultáneamente la solución compromiso y las políticas de carbono para poder encontrar los precios óptimos que permitan establecer políticas que no afecten la viabilidad económica de los proyectos y que no representen una inversión poco atractiva en los mercados de carbono.

Transición energética sustentable

Se desarrolló un modelo de optimización multiobjetivo para seleccionar el tipo, la capacidad y las ubicaciones de las tecnologías de energía renovable en una perspectiva nacional de transición energética. La información (real) del sistema eléctrico peninsular español se consideró como un caso de estudio para mostrar la aplicabilidad del modelo

propuesto. Se demostró que el modelo puede emular el sistema real como se presenta en la Figura 5.6. Se calculó que el sistema actual genera 0.19 tCO₂eq/MWh y el consumo de agua es de 1,218 L/MWh y la transición energética propuesta, considerando la minimización de TAC, alcanza una reducción en las emisiones de GEI del 21% y se disminuye la intensidad del consumo de agua en un 16,67%. Por otro lado, la solución de la formulación de transición energética multiobjetivo trae reducciones de 49.7% y 37.5% en las emisiones de GEI y el consumo de agua, respectivamente, en comparación con el sistema actual.

Los resultados en todos los escenarios traen beneficios ambientales utilizando la combinación propuesta de tecnologías renovables. Sin embargo, es necesario tener en cuenta que el ciclo combinado y la cogeneración juegan un papel clave en la estructura de generación. Estas tecnologías no funcionan a plena capacidad, por lo que representan un fuerte respaldo cuando las fuentes de energía variantes (eólica y solar) tienen un déficit.

Se demostró la importancia de considerar la intensidad del consumo de agua en la transición energética. Los trabajos futuros deben prestar especial atención a este parámetro y se pueden agregar restricciones que consideren la escasez de agua al modelo matemático.

Conclusión

En este trabajo de Tesis se desarrollaron modelos de optimización, con aplicaciones muy diversas, utilizando los métodos y estrategias que se han desarrollado en Ingeniería de Procesos (*Process Systems Engineering*). Los modelos de optimización que se desarrollaron brindan información útil sobre las implicaciones de elegir una tecnología, un diseño, una localización, una política y/o un método de solución como se presentó anteriormente. Se observó que los modelos propuestos nos ayudan a identificar las mejores características de nuestros sistemas, pero estas cambian en función de nuestros intereses ya sean ambientales, económicos, sociales o una combinación de ellos.

Es importante mencionar que todos los modelos matemáticos incluyen simplificaciones que nos alejan de una solución exacta, no obstante, eso no quiere decir que no provean información valiosa y el nivel de detalle requerido en los modelos dependerá de las aplicaciones.

Utilizar modelos de optimización nos permite planear y evaluar diferentes escenarios sin la necesidad de invertir en infraestructura nueva, dándonos la flexibilidad de explorar las

consecuencias de sucesos poco favorecedores a nuestros intereses. Por ello, es importante continuar desarrollando modelos y metodologías que ayuden a capturar el comportamiento de la realidad, por ejemplo, la incertidumbre o los esquemas de justicia en la optimización multiobjetivo. Las herramientas de simulación, modelado, optimización y control que se han desarrollado en ingeniería de procesos y que típicamente se han aplicado a la industria, tiene un gran potencial para ofrecer soluciones en el cumplimiento de los Objetivos de Desarrollo Sostenible, como se mostró en esta Tesis, por lo que se deben combinar con otras áreas del conocimiento para ofrecer soluciones que vayan más allá de los aspectos puramente técnicos y consideren de una mejor manera los aspectos económicos y sociales.

Apéndice

Publicaciones derivadas de este documento

Las siguientes publicaciones se realizaron durante los estudios en el Doctorado en Ciencias en Ingeniería Química y se derivan de los resultados reportados en este documento.

- **Tovar-Facio, J.**, Guerras, L. S., Ponce-Ortega, J. M., & Martín, M. (2020). Sustainable Energy Transition Considering the Water-Energy Nexus: A Multiobjective Optimization Framework. *Under Review*.
- **Tovar-Facio, J.**, Fuentes-Cortés, L. F., & Ponce-Ortega, J. M. (2019). Carbon price evaluation in power systems for flaring mitigation. *Journal of Sustainable Development of Energy, Water and Environment Systems*, 7(4), 716-729.
- **Tovar-Facio, J.**, Cao, Y., Ponce-Ortega, J. M., & Zavala, V. M. (2018). Scalable solution strategies for chance-constrained nonlinear programs. *Industrial & Engineering Chemistry Research*, 57(23), 7987-7998.

Publicaciones no reportadas en este documento

Las siguientes publicaciones se realizaron durante los estudios en el Doctorado en Ciencias en Ingeniería Química. Sin embargo, no se incluyeron en este trabajo por las siguientes razones. Primero, Los trabajos “Stochastic Optimization of the Water-Energy-Food Nexus in Disadvantaged Rural Communities to Achieve the Sustainable Development Goals” y “Effective use of carbon pricing on climate change mitigation projects: Analysis of the biogas supply chain to substitute liquefied-petroleum gas in Mexico” fueron colaboraciones en donde se aparece como segundo autor. Por otro lado, la publicación “Optimal Design of Cogeneration Systems to Use Uncertain Flare Streams” fue producto de la continuación de la tesis de maestría “Diseño Óptimo de Sistemas de Cogeneración Operando bajo Situaciones Anormales” y mucho de los resultados ya fueron reportados en la tesis mencionada. Finalmente, el artículo “Sustainable Energy Transition: Modeling and Optimization” se realizó durante el periodo de revisión de tesis por parte de los sinodales.

- **Tovar-Facio, J.**, Martín M. & Ponce-Ortega, J. M. (2020). Sustainable Energy Transition: Modeling and Optimization. *Under Review*.
- Cansino-Loeza, B., **Tovar-Facio, J.**, & Ponce-Ortega, J. M. (2020). Stochastic Optimization of the Water-Energy-Food Nexus in Disadvantaged Rural Communities to Achieve the Sustainable Development Goals. *Under Review*.
- Díaz-Trujillo, L. A., **Tovar-Facio, J.**, Nápoles-Rivera, F., & Ponce-Ortega, J. M. (2019). Effective use of carbon pricing on climate change mitigation projects: Analysis of the biogas supply chain to substitute liquefied-petroleum gas in Mexico. *Processes*, 7(10), 668.
- **Tovar-Facio, J.**, Eljack, F., Ponce-Ortega, J. M., & El-Halwagi, M. M. (2017). Optimal Design of Cogeneration Systems to Use Uncertain Flare Streams. *Industrial & Engineering Chemistry Research*, 56(24), 7049-7061.

Otras publicaciones

- **Tovar-Facio, J.**, Cao, Y., Ponce-Ortega, J. M., & Zavala, V. M. (2019). A Chance-Constrained Nonlinear Programming Approach for Equipment Design Under Uncertainty. In *Computer Aided Chemical Engineering* (Vol. 46, pp. 997-1002). Elsevier.
- **Tovar-Facio, J.**, Eljack, F., Ponce-Ortega, J. M., & El-Halwagi, M. M. (2017). Optimal design of multipiant cogeneration systems with uncertain flaring and venting. *ACS Sustainable Chemistry & Engineering*, 5(1), 675-688.
- **Tovar-Facio, J.**, Eljack, F., Ponce-Ortega, J. M., & El-Halwagi, M. M. (2017). Optimal Design of Cogeneration Systems Based on Flaring and Venting Streams and Accounting for the Involved Uncertainty. In *Computer Aided Chemical Engineering* (Vol. 40, pp. 937-942). Elsevier.
- **Tovar-Facio, J.**, Lira-Barragán, L. F., Nápoles-Rivera, F., Bamufleh, H. S., Ponce-Ortega, J. M., & El-Halwagi, M. M. (2016). Optimal synthesis of refinery property-based water networks with electrocoagulation treatment systems. *ACS Sustainable Chemistry & Engineering*, 4(1), 147-158.

Bibliografía

- [1] T. Edgar, D. Himmelblau, and L. Lasdon, *Optimization of chemical processes*, Second. Ney York, NY: McGraw-Hill, 2001.
- [2] K. Arredondo-Ramírez, J. M. Ponce-Ortega, and M. M. El-Halwagi, “Optimal planning and infrastructure development for shale gas production,” *Energy Convers. Manag.*, vol. 119, pp. 91–100, Jul. 2016.
- [3] L. A. Díaz-Trujillo and F. Nápoles-Rivera, “Optimization of biogas supply chain in Mexico considering economic and environmental aspects,” *Renew. Energy*, vol. 139, pp. 1227–1240, Aug. 2019.
- [4] J. Tovar-Facio, L. S. Guerras, J. M. Ponce-Ortega, and M. Martín, “Optimization Framework for a Sustainable Energy Transition Considering the Water-Energy Nexus,” *Manuscr. submitted Publ.*, 2020.
- [5] A. del C. Munguía-López, A. M. Sampat, E. Rubio-Castro, J. M. Ponce-Ortega, and V. M. Zavala, “Fairness-guided design of water distribution networks for agricultural lands,” *Comput. Chem. Eng.*, vol. 130, p. 106547, Nov. 2019.
- [6] J. Tovar-Facio, Y. Cao, J. M. Ponce-Ortega, and V. M. Zavala, “A Chance-Constrained Nonlinear Programming Approach for Equipment Design Under Uncertainty,” *Comput. Aided Chem. Eng.*, vol. 46, pp. 997–1002, Jan. 2019.
- [7] K. Balasubramaniam, P. Saraf, P. Hazra, R. Hadidi, and E. Makram, “A MILP formulation for utility scale optimal demand side response,” in *IEEE Power and Energy Society General Meeting*, 2016, vol. 2016-November.
- [8] I. Nowak, N. Breinfeld, E. M. T. Hendrix, and G. Njacheun-Njanzoua, “Decomposition-based Inner- and Outer-Refinement Algorithms for Global Optimization,” *J. Glob. Optim.*, vol. 72, no. 2, pp. 305–321, Oct. 2018.
- [9] B. Cansino-Loeza, J. Tovar-Facio, and J. M. Ponce-Ortega, “Stochastic Optimization of Water-Energy-Food Nexus in Disadvantaged Rural Communities to Achieve the Sustainable Development Goals,” *Manuscr. submitted Publ.*, 2020.
- [10] J. Tovar-Facio, F. Eljack, J. M. Ponce-Ortega, and M. M. El-Halwagi, “Optimal Design of Multiplant Cogeneration Systems with Uncertain Flaring and Venting,”

- ACS Sustain. Chem. Eng.*, vol. 5, no. 1, pp. 675–688, Jan. 2016.
- [11] J. Tovar-Facio, F. Eljack, J. M. Ponce-Ortega, and M. M. El-Halwagi, “Optimal Design of Cogeneration Systems To Use Uncertain Flare Streams,” *Ind. Eng. Chem. Res.*, vol. 56, no. 24, pp. 7049–7061, Jun. 2017.
- [12] M. R. Bussieck and A. Meeraus, “General Algebraic Modeling System (GAMS),” Springer, Boston, MA, 2004, pp. 137–157.
- [13] R. Fourer, D. M. Gay, and B. W. Kernighan, “A Modeling Language for Mathematical Programming,” *Manage. Sci.*, vol. 36, no. 5, pp. 519–554, May 1990.
- [14] W. E. Hart, J. P. Watson, and D. L. Woodruff, “Pyomo: Modeling and solving mathematical programs in Python,” *Math. Program. Comput.*, vol. 3, no. 3, pp. 219–260, Aug. 2011.
- [15] I. Dunning, J. Huchette, and M. Lubin, “JuMP: A Modeling Language for Mathematical Optimization,” *SIAM Rev.*, vol. 59, no. 2, pp. 295–320, Jan. 2017.
- [16] U. Diwekar, *Introduction to applied optimization*. Springer Science & Business Media, 2008.
- [17] C. Bordin, H. O. Anuta, A. Crossland, I. L. Gutierrez, C. J. Dent, and D. Vigo, “A linear programming approach for battery degradation analysis and optimization in offgrid power systems with solar energy integration,” *Renew. Energy*, vol. 101, pp. 417–430, Feb. 2017.
- [18] J. Ma, X. Li, F. Zhou, and W. Hao, “Designing optimal autonomous vehicle sharing and reservation systems: A linear programming approach,” *Transp. Res. Part C Emerg. Technol.*, vol. 84, pp. 124–141, Nov. 2017.
- [19] P. He, T. S. Ng, and B. Su, “Energy-economic resilience with multi-region input–output linear programming models,” *Energy Econ.*, vol. 84, p. 104569, Oct. 2019.
- [20] R. Alaini, R. Rajikan, and S. M. Elias, “Diet optimization using linear programming to develop low cost cancer prevention food plan for selected adults in Kuala Lumpur, Malaysia,” *BMC Public Health*, vol. 19, no. 4, pp. 1–8, Jun. 2019.
- [21] C. A. Floudas, *Nonlinear and Mixed-Integer Optimization: Fundamentals and Applications*, vol. 2. 2008.
- [22] B. A. Murtagh and M. A. Saunders, “A projected Lagrangian algorithm and its implementation for sparse nonlinear constraints,” Springer, Berlin, Heidelberg, 1982,

- pp. 84–117.
- [23] A. S. Drud, “CONOPT—A Large-Scale GRG Code,” *ORSA J. Comput.*, vol. 6, no. 2, pp. 207–216, May 1994.
 - [24] J. Nocedal, “KNITRO: An Integrated Package for Nonlinear Optimization.” Springer, pp. 35–60, 2006.
 - [25] A. Wächter and L. T. Biegler, “On the Implementation of a Primal-Dual Interior Point Filter Line Search Algorithm for Large-Scale Nonlinear Programming,” *Math. Program.*, vol. 106, pp. 25–57, 2006.
 - [26] M. B.-N. methods for nonlinear and undefined 1972, “Constrained minimization using recursive equality quadratic programming,” *Acad. Press. New York*.
 - [27] U. M. G. Palomares and O. L. Mangasarian, “Superlinearly convergent quasi-newton algorithms for nonlinearly constrained optimization problems,” *Math. Program.*, vol. 11, no. 1, pp. 1–13, Dec. 1976.
 - [28] S. P. Han, “A globally convergent method for nonlinear programming,” *J. Optim. Theory Appl.*, vol. 22, no. 3, pp. 297–309, Jul. 1977.
 - [29] S. P. Han, “Superlinearly convergent variable metric algorithms for general nonlinear programming problems,” *Math. Program.*, vol. 11, no. 1, pp. 263–282, Dec. 1976.
 - [30] M. J. D. Powell, “Algorithms for nonlinear constraints that use lagrangian functions,” *Math. Program.*, vol. 14, no. 1, pp. 224–248, Dec. 1978.
 - [31] M. J. D. Powell, “A fast algorithm for nonlinearly constrained optimization calculations,” Springer, Berlin, Heidelberg, 1978, pp. 144–157.
 - [32] L. S. Lasdon, R. L. Fox, and M. W. Ratner, “Nonlinear optimization using the generalized reduced gradient method,” *Rev. française d’automatique, informatique, Rech. opérationnelle. Rech. opérationnelle*, vol. 8, no. 3, pp. 74–103, 1974.
 - [33] G. A. Gabriele and K. M. Ragsdell, “The generalized reduced gradient method: A reliable tool for optimal design,” *J. Manuf. Sci. Eng. Trans. ASME*, vol. 99, no. 2, pp. 394–400, May 1977.
 - [34] A. Forsgren, P. E. Gill, and M. H. Wright, “Interior methods for nonlinear optimization,” *SIAM Rev.*, vol. 44, no. 4, pp. 525–597, Dec. 2002.
 - [35] L. T. Biegler, “Nonlinear Optimization Strategies for Process Separations and Process Intensification,” *Chemie Ing. Tech.*, p. cite.202000014, May 2020.

- [36] Q. Tan, T. Wang, Y. Zhang, X. Miao, and J. Zhu, “Nonlinear multi-objective optimization model for a biomass direct-fired power generation supply chain using a case study in China,” *Energy*, vol. 139, pp. 1066–1079, Nov. 2017.
- [37] M. Soltani, R. Kerachian, M. R. Nikoo, and H. Noory, “Planning for agricultural return flow allocation: application of info-gap decision theory and a nonlinear CVaR-based optimization model,” *Environ. Sci. Pollut. Res.*, vol. 25, no. 25, pp. 25115–25129, Sep. 2018.
- [38] J. Hao, Q. Feng, W. Suo, G. Gao, and X. Sun, “Ensemble forecasting for electricity consumption based on nonlinear optimization,” in *Procedia Computer Science*, 2019, vol. 162, pp. 19–24.
- [39] R. J. Dakin, “A tree-search algorithm for mixed integer programming problems,” *Comput. J.*, vol. 8, no. 3, pp. 250–255, Jan. 1965.
- [40] R. E. Gomory, “Outline of an algorithm for integer solutions to linear programs and an algorithm for the mixed integer problem,” in *50 Years of Integer Programming 1958-2008: From the Early Years to the State-of-the-Art*, Springer Berlin Heidelberg, 2010, pp. 77–103.
- [41] J. F. Benders, “Partitioning procedures for solving mixed-variables programming problems ’,” *Numer. Math.*, 1962.
- [42] S. H. Owen and M. S. Daskin, “Strategic facility location: A review,” *Eur. J. Oper. Res.*, vol. 111, no. 3, pp. 423–447, Dec. 1998.
- [43] O. Koné, C. Artigues, P. Lopez, and M. Mongeau, “Event-based MILP models for resource-constrained project scheduling problems,” in *Computers and Operations Research*, 2011, vol. 38, no. 1, pp. 3–13.
- [44] S. D. Ekşioğlu, H. Edwin Romeijn, and P. M. Pardalos, “Cross-facility management of production and transportation planning problem,” *Comput. Oper. Res.*, vol. 33, no. 11, pp. 3231–3251, Nov. 2006.
- [45] N. Bieber y col., “Sustainable planning of the energy-water-food nexus using decision making tools,” *Energy Policy*, vol. 113, pp. 584–607, Feb. 2018.
- [46] E. Karan, S. Asadi, R. Mohtar, and M. Baawain, “Towards the optimization of sustainable food-energy-water systems: A stochastic approach,” *J. Clean. Prod.*, vol. 171, pp. 662–674, Jan. 2018.

- [47] D. J. Garcia and F. You, “The water-energy-food nexus and process systems engineering: A new focus,” *Comput. Chem. Eng.*, vol. 91, pp. 49–67, Aug. 2016.
- [48] B. Cansino-Loeza and J. M. Ponce-Ortega, “Involving the Water-Energy-Food Nexus in Integrating Low-Income and Isolated Communities,” *ACS Sustain. Chem. Eng.*, vol. 7, no. 1, pp. 1399–1418, Jan. 2019.
- [49] D. C. López-Díaz, L. F. Lira-Barragán, E. Rubio-Castro, M. Serna-González, M. M. El-Halwagi, and J. M. Ponce-Ortega, “Optimization of biofuels production via a water–energy–food nexus framework,” *Clean Technol. Environ. Policy*, vol. 20, no. 7, pp. 1443–1466, Sep. 2018.
- [50] H. Aldana, F. J. Lozano, and J. Acevedo, “Evaluating the potential for producing energy from agricultural residues in México using MILP optimization,” *Biomass and Bioenergy*, vol. 67, pp. 372–389, Aug. 2014.
- [51] B. T. C. Tiu and D. E. Cruz, “An MILP model for optimizing water exchanges in eco-industrial parks considering water quality,” *Resour. Conserv. Recycl.*, vol. 119, pp. 89–96, Apr. 2017.
- [52] W. M. Chan, Y. T. Leong, and I. M. L. Chew, “Multiple-criteria evaluation of centralized chilled water hub powered by industrial waste heat and renewable energy,” *J. Clean. Prod.*, vol. 247, p. 119570, Feb. 2020.
- [53] S. I. Pérez-Uresti, M. Martín, and A. Jiménez-Gutiérrez, “A Methodology for the Design of Flexible Renewable-Based Utility Plants,” *ACS Sustain. Chem. Eng.*, vol. 8, no. 11, pp. 4580–4597, Mar. 2020.
- [54] N. Vanzetti, D. Broz, J. M. Montagna, and G. Corsano, “Integrated approach for the bucking and production planning problems in forest industry,” *Comput. Chem. Eng.*, vol. 125, pp. 155–163, Jun. 2019.
- [55] A. D. F. Sánchez-Bautista, J. E. Santibanez-Aguilar, F. You, and J. M. Ponce-Ortega, “Optimal Design of Energy Systems Involving Pollution Trading through Forest Plantations,” *ACS Sustain. Chem. Eng.*, vol. 5, no. 3, pp. 2585–2604, Mar. 2017.
- [56] M. A. Méndez-Vázquez, F. I. Gómez-Castro, J. M. Ponce-Ortega, A. H. Serafín-Muñoz, J. E. Santibañez-Aguilar, and M. M. El-Halwagi, “Mathematical optimization of a supply chain for the production of fuel pellets from residual biomass,” *Clean Technol. Environ. Policy*, vol. 19, no. 3, pp. 721–734, Jul. 2017.

- [57] S. Domínguez-García, C. Gutiérrez-Antonio, J. A. De Lira-Flores, and J. M. Ponce-Ortega, "Optimal planning for the supply chain of biofuels for aviation in Mexico," *Clean Technol. Environ. Policy*, vol. 19, no. 5, pp. 1387–1402, Feb. 2017.
- [58] L. A. Díaz-Trujillo, J. Tovar-Facio, F. Nápoles-Rivera, and J. M. Ponce-Ortega, "Effective Use of Carbon Pricing on Climate Change Mitigation Projects: Analysis of the Biogas Supply Chain to Substitute Liquefied-Petroleum Gas in Mexico," *Processes*, vol. 7, no. 10, p. 668, Sep. 2019.
- [59] O. K. Gupta and A. Ravindran, "BRANCH AND BOUND EXPERIMENTS IN CONVEX NONLINEAR INTEGER PROGRAMMING.," *Manage. Sci.*, vol. 31, no. 12, pp. 1533–1546, Dec. 1985.
- [60] R. A. Stubbs and S. Mehrotra, "A branch-and-cut method for 0-1 mixed convex programming," *Math. Program. Ser. B*, vol. 86, no. 3, pp. 515–532, 1999.
- [61] A. M. Geoffrion, "Generalized Benders decomposition," *J. Optim. Theory Appl.*, vol. 10, no. 4, pp. 237–260, Oct. 1972.
- [62] M. A. Duran and I. E. Grossmann, "An outer-approximation algorithm for a class of mixed-integer nonlinear programs," *Math. Program.*, vol. 36, no. 3, pp. 307–339, Oct. 1986.
- [63] J. Tovar-Facio, L. F. Lira-Barragán, F. Nápoles-Rivera, H. S. Bamufleh, J. M. Ponce-Ortega, and M. M. El-Halwagi, "Optimal Synthesis of Refinery Property-Based Water Networks with Electrocoagulation Treatment Systems," *ACS Sustain. Chem. Eng.*, vol. 4, no. 1, pp. 147–158, Jan. 2016.
- [64] Á. M. González Rueda, J. González Díaz, and M. P. Fernández de Córdoba, "A twist on SLP algorithms for NLP and MINLP problems: an application to gas transmission networks," *Optim. Eng.*, vol. 20, no. 2, pp. 349–395, Jun. 2019.
- [65] M. Marzband, A. Sumper, J. L. Domínguez-García, and R. Gumara-Ferret, "Experimental validation of a real time energy management system for microgrids in islanded mode using a local day-ahead electricity market and MINLP," *Energy Convers. Manag.*, vol. 76, pp. 314–322, Dec. 2013.
- [66] J. F. Hernández-Martinez, E. Rubio-Castro, M. Serna-González, M. M. El-Halwagi, and J. M. Ponce-Ortega, "Optimal Design of Integrated Solar Power Plants Accounting for the Thermal Storage System and CO₂ Mitigation through an Algae

- System,” *Ind. Eng. Chem. Res.*, vol. 55, no. 41, pp. 11003–11011, Oct. 2016.
- [67] Y. Li, B. Feng, G. Li, J. Qi, D. Zhao, and Y. Mu, “Optimal distributed generation planning in active distribution networks considering integration of energy storage,” *Appl. Energy*, vol. 210, pp. 1073–1081, Jan. 2018.
- [68] L. F. Fuentes-Cortés, R. González-Bravo, A. Flores-Tlacuahuac, and J. M. Ponce-Ortega, “Optimal sustainable water-Energy storage strategies for off-grid systems in low-income communities,” *Comput. Chem. Eng.*, vol. 123, pp. 87–109, Apr. 2019.
- [69] M. Ramos-Castillo, M. Orvain, G. Naves-Maschietto, A. B. B. de Faria, D. Chenu, and M. Albuquerque, “Optimal agricultural spreading scheduling through surrogate-based optimization and MINLP models,” *Inf. Process. Agric.*, Mar. 2020.
- [70] G. B. Dantzig, “Linear Programming Under Uncertainty,” Springer, New York, NY, 2010, pp. 1–11.
- [71] S. Sen and J. L. Higle, “An introductory tutorial on stochastic linear programming models,” *Interfaces (Providence)*, vol. 29, no. 2, pp. 33–61, 1999.
- [72] N. V. Sahinidis, “Optimization under uncertainty: State-of-the-art and opportunities,” in *Computers and Chemical Engineering*, 2004, vol. 28, no. 6–7, pp. 971–983.
- [73] D. Bienstock, M. Chertkov, and S. Harnett, “Chance-Constrained Optimal Power Flow: Risk-Aware Network Control under Uncertainty,” *SIAM Rev.*, vol. 56, no. 3, pp. 461–495, Jan. 2014.
- [74] W. Van Ackooij and R. Henrion, “Gradient Formulae for Nonlinear Probabilistic Constraints with Gaussian and Gaussian-Like Distributions,” *SIAM J. Optim.*, vol. 24, no. 4, pp. 1864–1889, Jan. 2014.
- [75] J. Luedtke, S. Ahmed, and G. L. Nemhauser, “An integer programming approach for linear programs with probabilistic constraints,” *Math. Program.*, vol. 122, no. 2, pp. 247–272, Apr. 2010.
- [76] A. Nemirovski and A. Shapiro, *In Probabilistic and Randomized Methods for Design under Uncertainty*. London: Springer London, 2006.
- [77] G. Calafiore and M. C. Campi, “Uncertain convex programs: randomized solutions and confidence levels,” *Math. Program.*, vol. 102, no. 1, pp. 25–46, 2005.
- [78] J. Kang, N. Chiang, C. D. Laird, and V. M. Zavala, “Nonlinear programming strategies on high-performance computers,” in *2015 54th IEEE Conference on Decision and*

- Control (CDC)*, 2015, pp. 4612–4620.
- [79] A. Nemirovski and A. Shapiro, “Convex Approximations of Chance Constrained Programs,” *SIAM J. Optim.*, vol. 17, no. 4, pp. 969–996, Jan. 2007.
- [80] L. J. Hong, Y. Yang, and L. Zhang, “Sequential convex approximations to joint chance constrained programs: A Monte Carlo approach,” *Oper. Res.*, vol. 59, no. 3, pp. 617–630, 2011.
- [81] J. A. Paulson, E. A. Buehler, R. D. Braatz, and A. Mesbah, “Stochastic model predictive control with joint chance constraints,” *Int. J. Control*, vol. 93, no. 1, pp. 126–139, Jan. 2017.
- [82] Y. Cao, V. M. Zavala, and F. D’Amato, “Using stochastic programming and statistical extrapolation to mitigate long-term extreme loads in wind turbines,” *Appl. Energy*, vol. 230, pp. 1230–1241, Nov. 2018.
- [83] P. Ragan and L. Manuel, “Statistical extrapolation methods for estimating wind turbine extreme loads,” *J. Sol. Energy Eng.*, vol. 130, no. 3, p. 31011, Aug. 2008.
- [84] W. T. Song, “Relationships among some univariate distributions,” *IIE Trans.*, vol. 37, no. 7, pp. 651–656, Jul. 2005.
- [85] R. T. Rockafellar and S. Uryasev, “Optimization of conditional value-at-risk,” *J. risk*, vol. 2, no. 3, pp. 21–42, 2000.
- [86] C. Chen and O. L. Mangasarian, “Smoothing methods for convex inequalities and linear complementarity problems,” *Math. Program.*, vol. 71, no. 1, pp. 51–69, 1995.
- [87] Y. Cao and V. M. Zavala, “A Sigmoidal Approximation for Chance-Constrained Nonlinear Programs,” vol. Under Revi, Apr. 2020.
- [88] N.-Y. Chiang and V. M. Zavala, “An inertia-free filter line-search algorithm for large-scale nonlinear programming,” *Comput. Optim. Appl.*, vol. 64, no. 2, pp. 327–354, 2016.
- [89] M. A. Ramos, M. Boix, L. Montastruc, and S. Domenech, “Multiobjective optimization using goal programming for industrial water network design,” *Ind. Eng. Chem. Res.*, vol. 53, no. 45, pp. 17722–17735, Nov. 2014.
- [90] G. P. Rangaiah and A. Bonilla-Petriciolet, *Multi-Objective Optimization in Chemical Engineering*. Oxford, UK: John Wiley & Sons Ltd, 2013.
- [91] R. T. Marler and J. S. Arora, “The weighted sum method for multi-objective

- optimization: New insights,” *Struct. Multidiscip. Optim.*, vol. 41, no. 6, pp. 853–862, Jun. 2010.
- [92] U. Diwekar, “Multiobjective optimization,” in *Springer Optimization and Its Applications*, vol. 22, Springer International Publishing, 2008, pp. 179–214.
- [93] J. Kearns, K. Armstrong, L. Shirvill, E. Garland, and C. S. Report, “Flaring and venting in the oil and gas exploration and production industry, international association of oil,” 2000.
- [94] J. L. Sorrels, J. Coburn, K. Bradley, and D. Randall, “Chapter 1. Flares,” in *EPA Air Pollution Control Cost Manual*, United States, Environmental Protection Agency, 2017.
- [95] R. P. API, “521,” *Recomm. Pract.*, vol. 521, no. 3, 1997.
- [96] J. Bezanson, A. Edelman, S. Karpinski, and V. B. Shah, “Julia: A fresh approach to numerical computing,” *SIAM Rev.*, vol. 59, no. 1, pp. 65–98, 2017.
- [97] World Bank, IFC, and MIGA, “World Bank Group Climate Change Action Plan 2016-2020,” World Bank, Washington, DC, USA, Jun. 2016.
- [98] S. Solaymani, “CO2 emissions patterns in 7 top carbon emitter economies: The case of transport sector,” *Energy*, vol. 168, pp. 989–1001, Feb. 2019.
- [99] R. G. Newell, A. B. Jaffe, and R. N. Stavins, “The effects of economic and policy incentives on carbon mitigation technologies,” *Energy Econ.*, vol. 28, no. 5–6, pp. 563–578, Nov. 2006.
- [100] Q.-M. Liang, Y.-F. Yao, L.-T. Zhao, C. Wang, R.-G. Yang, and Y.-M. Wei, “Platform for China Energy & Environmental Policy Analysis: A general design and its application,” *Environ. Model. Softw.*, vol. 51, pp. 195–206, Jan. 2014.
- [101] A. Zakeri, F. Dehghanian, B. Fahimnia, and J. Sarkis, “Carbon pricing versus emissions trading: A supply chain planning perspective,” *Int. J. Prod. Econ.*, vol. 164, pp. 197–205, Jun. 2015.
- [102] F.-P. Chiu, H.-I. Kuo, C.-C. Chen, and C.-S. Hsu, “The energy price equivalence of carbon taxes and emissions trading—Theory and evidence,” *Appl. Energy*, vol. 160, pp. 164–171, Dec. 2015.
- [103] L.-B. Cui, Y. Fan, L. Zhu, and Q.-H. Bi, “How will the emissions trading scheme save cost for achieving China’s 2020 carbon intensity reduction target?,” *Appl. Energy*, vol.

- 136, pp. 1043–1052, Dec. 2014.
- [104] W. Li and Z. Jia, “Carbon tax, emission trading, or the mixed policy: which is the most effective strategy for climate change mitigation in China?,” *Mitig. Adapt. Strateg. Glob. Chang.*, vol. 22, no. 6, pp. 973–992, Aug. 2017.
- [105] World Bank and Ecofys, “State and trends of carbon pricing 2018 (May),” *World Bank, Washington, DC, USA*, 2018.
- [106] J. Carl and D. Fedor, “Tracking global carbon revenues: A survey of carbon taxes versus cap-and-trade in the real world,” *Energy Policy*, vol. 96, pp. 50–77, Sep. 2016.
- [107] J. Skovgaard and H. van Asselt, “The politics of fossil fuel subsidies and their reform: Implications for climate change mitigation,” *Wiley Interdiscip. Rev. Clim. Chang.*, vol. 10, no. 4, p. e581, Jul. 2019.
- [108] L. F. Fuentes-Cortés, Y. Ma, J. M. Ponce-Ortega, G. Ruiz-Mercado, and V. M. Zavala, “Valuation of water and emissions in energy systems,” *Appl. Energy*, vol. 210, pp. 518–528, Jan. 2018.
- [109] M. Otaki, “Emission trading or proportional carbon tax: a quest for more efficacious emission control,” *Environ. Syst. Res.*, vol. 2, no. 1, p. 8, Oct. 2013.
- [110] E. Gawel, S. Strunz, and P. Lehmann, “A public choice view on the climate and energy policy mix in the EU — How do the emissions trading scheme and support for renewable energies interact?,” *Energy Policy*, vol. 64, pp. 175–182, Jan. 2014.
- [111] L. K. Wang, N. C. Pereira, and Y.-T. Hung, Eds., *Air Pollution Control Engineering*. Totowa, NJ: Humana Press, 2004.
- [112] M. F. Farina, “Flare Gas Reduction Recent global trends and policy considerations,” 2010.
- [113] I. Onwukwe Stanley, “Gas-to-Liquid technology: Prospect for natural gas utilization in Nigeria,” *J. Nat. Gas Sci. Eng.*, vol. 1, no. 6, pp. 190–194, Dec. 2009.
- [114] G. Comodi, M. Renzi, and M. Rossi, “Energy efficiency improvement in oil refineries through flare gas recovery technique to meet the emission trading targets,” *Energy*, vol. 109, pp. 1–12, Aug. 2016.
- [115] A. Hajizadeh, M. Mohamadi-Baghmolaei, R. Azin, S. Osfouri, and I. Heydari, “Technical and economic evaluation of flare gas recovery in a giant gas refinery,” *Chem. Eng. Res. Des.*, vol. 131, pp. 506–519, Mar. 2018.

- [116] M. Heidari, A. Ataei, and M. H. Rahdar, "Development and analysis of two novel methods for power generation from flare gas," *Appl. Therm. Eng.*, vol. 104, pp. 687–696, Jul. 2016.
- [117] M.-K. K. Kazi, F. Mohammed, A. M. N. AlNouss, and F. Eljack, "Multi-objective optimization methodology to size cogeneration systems for managing flares from uncertain sources during abnormal process operations," vol. 76, pp. 76–86, May 2015.
- [118] M. K. Kazi, F. Eljack, N. A. Elsayed, and M. M. El-Halwagi, "Integration of Energy and Wastewater Treatment Alternatives with Process Facilities to Manage Industrial Flares during Normal and Abnormal Operations: Multiobjective Extendible Optimization Framework," *Ind. Eng. Chem. Res.*, vol. 55, no. 7, pp. 2020–2034, Feb. 2016.
- [119] M. R. Rahimpour and S. M. Jokar, "Feasibility of flare gas reformation to practical energy in Farashband gas refinery: No gas flaring," *J. Hazard. Mater.*, vol. 209–210, pp. 204–217, Mar. 2012.
- [120] M. Zolfaghari, V. Pirouzfard, and H. Sakhaeinia, "Technical characterization and economic evaluation of recovery of flare gas in various gas-processing plants," *Energy*, vol. 124, pp. 481–491, Apr. 2017.
- [121] G. D. Ulrich and P. T. Vasudevan, "How to Estimate Utility Costs," *Chem. Eng.*, pp. 66–69, 2006.
- [122] J. C. Bruno, F. Fernandez, F. Castells, and I. E. Grossmann, "A rigorous minlp model for the optimal synthesis and operation of utility plants," *Chem. Eng. Res. Des.*, vol. 76, no. 3, pp. 246–258, Mar. 1998.
- [123] EIA, "International Energy Outlook 2019," 2019. [Online]. Available: <https://www.eia.gov/outlooks/ieo/>. [Accessed: 21-Apr-2020].
- [124] UNFCCC, "The Paris Agreement," 2015. [Online]. Available: <https://unfccc.int/process-and-meetings/the-paris-agreement/the-paris-agreement>. [Accessed: 11-May-2020].
- [125] IRENA, "Power system flexibility for the energy transition, Part 1: Overview for policy makers," Sbu Dhabi, 2018.
- [126] D. García-Gusano and D. Iribarren, "Prospective energy security scenarios in Spain: The future role of renewable power generation technologies and climate change

- implications,” *Renew. Energy*, vol. 126, pp. 202–209, Oct. 2018.
- [127] S. Kwon, Y. Xu, and N. Gautam, “Meeting Inelastic Demand in Systems with Storage and Renewable Sources,” *IEEE Trans. Smart Grid*, vol. 8, no. 4, pp. 1619–1629, Jul. 2017.
- [128] M. Victoria and C. Gallego-Castillo, “Hourly-resolution analysis of electricity decarbonization in Spain (2017–2030),” *Appl. Energy*, vol. 233–234, pp. 674–690, Jan. 2019.
- [129] C. F. Heuberger, E. S. Rubin, I. Staffell, N. Shah, and N. Mac Dowell, “Power capacity expansion planning considering endogenous technology cost learning,” *Appl. Energy*, vol. 204, pp. 831–845, Oct. 2017.
- [130] G. Pleßmann and P. Blechinger, “How to meet EU GHG emission reduction targets? A model based decarbonization pathway for Europe’s electricity supply system until 2050,” *Energy Strateg. Rev.*, vol. 15, pp. 19–32, Mar. 2017.
- [131] C. Gerbaulet, C. von Hirschhausen, C. Kemfert, C. Lorenz, and P.-Y. Oei, “Scenarios for decarbonizing the European electricity sector,” in *2017 14th International Conference on the European Energy Market (EEM)*, 2017, pp. 1–6.
- [132] F. Kern and A. Smith, “Restructuring energy systems for sustainability? Energy transition policy in the Netherlands,” *Energy Policy*, vol. 36, no. 11, pp. 4093–4103, Nov. 2008.
- [133] L. C. Stokes and H. L. Breetz, “Politics in the U.S. energy transition: Case studies of solar, wind, biofuels and electric vehicles policy,” *Energy Policy*, vol. 113, pp. 76–86, Feb. 2018.
- [134] M. S. Shahid, R. N. Lodhi, and A. R. Gill, “An Energy Transition Model for Pakistan’s Electricity System: Scenarios and Their Implications,” *Environ. Prog. Sustain. Energy*, vol. 38, no. 5, p. 13210, Sep. 2019.
- [135] K. Hansen, B. V. Mathiesen, and I. R. Skov, “Full energy system transition towards 100% renewable energy in Germany in 2050,” *Renew. Sustain. Energy Rev.*, vol. 102, pp. 1–13, Mar. 2019.
- [136] J. J. Vidal-Amaro, P. A. Østergaard, and C. Sheinbaum-Pardo, “Optimal energy mix for transitioning from fossil fuels to renewable energy sources - The case of the Mexican electricity system,” *Appl. Energy*, vol. 150, pp. 80–96, Jul. 2015.

- [137] A. J. Chapman and K. Itaoka, “Energy transition to a future low-carbon energy society in Japan’s liberalizing electricity market: Precedents, policies and factors of successful transition,” *Renew. Sustain. Energy Rev.*, vol. 81, pp. 2019–2027, Jan. 2018.
- [138] A. M.-Z. Gao, C.-T. Fan, and C.-N. Liao, “Application of German energy transition in Taiwan: A critical review of unique electricity liberalisation as a core strategy to achieve renewable energy growth,” *Energy Policy*, vol. 120, pp. 644–654, Sep. 2018.
- [139] K. Gürtler, R. Postpischil, and R. Quitzow, “The dismantling of renewable energy policies: The cases of Spain and the Czech Republic,” *Energy Policy*, vol. 133, p. 110881, Oct. 2019.
- [140] D. García-Gusano, D. Garraín, and J. Dufour, “Prospective life cycle assessment of the Spanish electricity production,” *Renew. Sustain. Energy Rev.*, vol. 75, pp. 21–34, Aug. 2017.
- [141] R. Gómez-Calvet, J. M. Martínez-Duart, and S. Serrano-Calle, “Current state and optimal development of the renewable electricity generation mix in Spain,” *Renew. Energy*, vol. 135, pp. 1108–1120, May 2019.
- [142] R. Gómez-Calvet, J. M. Martínez-Duart, and S. Serrano Calle, “Present state and perspectives of variable renewable energies in Spain,” *Eur. Phys. J. Plus*, vol. 133, no. 3, p. 126, Mar. 2018.
- [143] C. F. Heuberger and N. Mac Dowell, “Real-World Challenges with a Rapid Transition to 100% Renewable Power Systems,” *Joule*, vol. 2, no. 3, pp. 367–370, Mar. 2018.
- [144] R. Fernández-Blanco, K. Kavvadias, and I. Hidalgo González, “Quantifying the water-power linkage on hydrothermal power systems: A Greek case study,” *Appl. Energy*, vol. 203, pp. 240–253, Oct. 2017.
- [145] L. Scherer and S. Pfister, “Global water footprint assessment of hydropower,” *Renew. Energy*, vol. 99, pp. 711–720, Dec. 2016.
- [146] Y. Zhu, J. Liang, Q. Yang, H. Zhou, and K. Peng, “Water use of a biomass direct-combustion power generation system in China: A combination of life cycle assessment and water footprint analysis,” *Renew. Sustain. Energy Rev.*, vol. 115, p. 109396, Nov. 2019.
- [147] M. Drews, M. A. D. Larsen, and J. G. Peña Balderrama, “Projected water usage and land-use-change emissions from biomass production (2015–2050),” *Energy Strateg.*

- Rev.*, vol. 29, p. 100487, May 2020.
- [148] S. Bukhary, S. Ahmad, and J. Batista, “Analyzing land and water requirements for solar deployment in the Southwestern United States,” *Renew. Sustain. Energy Rev.*, vol. 82, pp. 3288–3305, Feb. 2018.
- [149] I. Capellán-Pérez, C. de Castro, and I. Arto, “Assessing vulnerabilities and limits in the transition to renewable energies: Land requirements under 100% solar energy scenarios,” *Renew. Sustain. Energy Rev.*, vol. 77, pp. 760–782, Sep. 2017.
- [150] N. Nouri, F. Balali, A. Nasiri, H. Seifoddini, and W. Otieno, “Water withdrawal and consumption reduction for electrical energy generation systems,” *Appl. Energy*, vol. 248, pp. 196–206, Aug. 2019.
- [151] U. Lee, J. Han, A. Elgowainy, and M. Wang, “Regional water consumption for hydro and thermal electricity generation in the United States,” *Appl. Energy*, vol. 210, pp. 661–672, Jan. 2018.
- [152] T. A. DeNooyer, J. M. Peschel, Z. Zhang, and A. S. Stillwell, “Integrating water resources and power generation: The energy-water nexus in Illinois,” *Appl. Energy*, vol. 162, pp. 363–371, Jan. 2016.
- [153] H. Medarac, D. Magagna, and I. Hidalgo-González, “Projected fresh water use from the European energy sector,” 2018.
- [154] R. Das *et al.*, “Multi-objective techno-economic-environmental optimisation of electric vehicle for energy services,” *Appl. Energy*, vol. 257, p. 113965, Jan. 2020.
- [155] R. Jing *et al.*, “A multi-objective optimization and multi-criteria evaluation integrated framework for distributed energy system optimal planning,” *Energy Convers. Manag.*, vol. 166, pp. 445–462, Jun. 2018.
- [156] A. de F. Sánchez-Bautista, J. E. Santibañez-Aguilar, L. F. Fuentes-Cortés, A. Flores-Tlacuahuac, and J. M. Ponce-Ortega, “A Multistakeholder Approach for the Optimal Planning of Sustainable Energy Systems,” *ACS Sustain. Chem. Eng.*, vol. 6, no. 7, pp. 9451–9460, Jul. 2018.
- [157] M. A. Gonzalez-Salazar, T. Kirsten, and L. Prchlik, “Review of the operational flexibility and emissions of gas- and coal-fired power plants in a future with growing renewables,” *Renew. Sustain. Energy Rev.*, vol. 82, pp. 1497–1513, Feb. 2018.
- [158] Y. Jin, P. Behrens, A. Tukker, and L. Scherer, “Water use of electricity technologies:

- A global meta-analysis,” *Renew. Sustain. Energy Rev.*, vol. 115, p. 109391, Nov. 2019.
- [159] L. S. Guerras and M. Martín, “On the water footprint in power production: Sustainable design of wet cooling towers,” *Appl. Energy*, vol. 263, p. 114620, Apr. 2020.
- [160] IPCC, “AR5 Climate Change 2014: Mitigation of Climate Change — IPCC,” 2014. [Online]. Available: <https://www.ipcc.ch/report/ar5/wg3/>. [Accessed: 14-Apr-2020].
- [161] I. Tsiropoulos, D. Tarvydas, and A. Zucker, “Cost development of low carbon energy technologies - Scenario-based cost trajectories to 2050, 2017 edition,” *JRC Sci. Policy Reports*, 2018.
- [162] NEA, IEA, and OECD, *Projected Costs of Generating Electricity 2015*. Paris: OECD Publishing, 2015.
- [163] J. G. Rogers and J. G. Brammer, “Analysis of transport costs for energy crops for use in biomass pyrolysis plant networks,” *Biomass and Bioenergy*, vol. 33, no. 10, pp. 1367–1375, Oct. 2009.
- [164] European Environment Agency, “Specific CO₂ emissions per tonne-km and per mode of transport in Europe — European Environment Agency,” 2017. [Online]. Available: https://www.eea.europa.eu/data-and-maps/daviz/specific-co2-emissions-per-tonne-2#tab-chart_2. [Accessed: 15-Apr-2020].
- [165] R. T. L. Ng and C. T. Maravelias, “Design of Cellulosic Ethanol Supply Chains with Regional Depots,” *Ind. Eng. Chem. Res.*, vol. 55, no. 12, pp. 3420–3432, Mar. 2016.
- [166] F. G. Montoya, M. J. Aguilera, and F. Manzano-Agugliaro, “Renewable energy production in Spain: A review,” *Renew. Sustain. Energy Rev.*, vol. 33, pp. 509–531, May 2014.
- [167] J. Pérez-García and J. Moral-Carcedo, “Analysis and long term forecasting of electricity demand through a decomposition model: A case study for Spain,” *Energy*, vol. 97, pp. 127–143, Feb. 2016.
- [168] G. Zubi, J. L. Bernal-Agustín, and A. B. Fandos Marín, “Wind energy (30%) in the Spanish power mix—technically feasible and economically reasonable,” *Energy Policy*, vol. 37, no. 8, pp. 3221–3226, Aug. 2009.
- [169] D. L. Talavera, P. Pérez-Higueras, J. A. Ruíz-Arias, and E. F. Fernández, “Levelised cost of electricity in high concentrated photovoltaic grid connected systems: Spatial

- analysis of Spain,” *Appl. Energy*, vol. 151, pp. 49–59, Aug. 2015.
- [170] REE, “Demand | Red Eléctrica de España,” 2019. [Online]. Available: <https://www.ree.es/en/datos/generation/generation-structure>. [Accessed: 13-Apr-2020].
- [171] T. Bruckner *et al.*, “Energy Systems. In: Climate Change 2014: Mitigation of Climate Change. Contribution of Working Group III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change,” in *Climate Change 2014: Mitigation of Climate Change. Contribution of Working Group III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, O. Edenhofer, R. Pichs-Madruga, Y. Sokona, E. Farahani, S. Kadner, K. Seyboth, A. Adler, I. Baum, S. Brunner, P. Eickemeier, B. Kriemann, J. Savolainen, S. Schlömer, C. von Stechow, T. Zwickel, and J. C. Minx, Eds. Cambridge, United Kingdom and New York, NY, USA.: Cambridge University Press, 2014.
- [172] REE, “Production Installations Map | ESIOS electricity data transparency,” 2019. [Online]. Available: <https://www.esios.ree.es/en/interesting-maps/production-installations-map>. [Accessed: 16-Apr-2020].
- [173] European Commission and Intelligent Energy Europe, “Biomass role in achieving the Climate Change & Renewables EU policy Targets. Demand and Supply dynamics under the perspective of Stakeholders.” [Online]. Available: <https://ec.europa.eu/energy/intelligent/projects/en/projects/biomass-futures>. [Accessed: 16-Apr-2020].
- [174] CIEMAT, “ADRASE - Access to Spanish solar radiation data - Mainland Spain and Balearic Islands.” [Online]. Available: <http://www.adrase.com/en/maps-access/spain-balearic-maps.html>. [Accessed: 16-Apr-2020].
- [175] CENER, “Global Wind, herramienta de análisis del potencial eólico.” [Online]. Available: <http://www.globalwindmap.com/VisorCENER/mapviewer.jsf?width=1293&height=684>. [Accessed: 22-Apr-2020].
- [176] REE, “REData | CO2 EQ. Emission factor and GHG emissions regarding non-renewable generation,” 2019. [Online]. Available: <https://www.ree.es/en/datos/generation/non-renewable-detail-CO2-emissions>.

[Accessed: 19-Apr-2020].

- [177] S. Schlömer *et al.*, “Annex III: Technology-specific cost and performance parameters,” in *Climate Change 2014: Mitigation of Climate Change. Contribution of Working Group III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, J. C. Edenhofer, O. Pichs-Madruga, R. Sokona, Y. Farahani, E. Kadner, S. Seyboth, K. Adler, A. Baum, I. Brunner, S. Eickemeier, P. Kriemann, B. Savolainen, J. Schlömer, S. Stechow, C. von Zwickel, T. Minx, Ed. United Kingdom and New York, NY, USA: Cambridge University Press, 2014.
- [178] Iberdrola, “Núñez de Balboa photovoltaic plant,” 2020. [Online]. Available: <https://www.iberdrola.com/about-us/lines-business/flagship-projects/nunez-de-balboa-photovoltaic-plant>. [Accessed: 19-Apr-2020].
- [179] REE, “Electricity demand tracking in real time, associated generation mix and CO2 emissions,” 2020. [Online]. Available: <https://demanda.ree.es/visiona/peninsula/demanda/total/2020-01-30>. [Accessed: 17-Apr-2020].