



UNIVERSIDAD NACIONAL DE COLOMBIA

Análisis de Métodos de Optimización Metaheurística para la Calibración de Modelos en Dinámica de Sistemas

Juan Felipe Parra Rodas

Universidad Nacional de Colombia

Facultad de Minas, Departamento de Ciencias de la Computación y la Decisión

Medellín, Colombia

2015

Análisis de Métodos de Optimización Metaheurística para la Calibración de Modelos en Dinámica de Sistemas

Juan Felipe Parra Rodas

Tesis o trabajo de investigación presentada(o) como requisito parcial para optar al título
de:

Magister en Ingeniería –Ingeniería de Sistemas.

Directora:

PhD. Gloria Patricia Jaramillo Álvarez

Codirector:

PhD. Santiago Arango Aramburo

Línea de Investigación:

Investigación de operaciones

Grupo de Investigación:

Grupo de Investigación en Ciencias de la Decisión

Universidad Nacional de Colombia

Facultad de Minas, Departamento de Ciencias de la Computación y la Decisión

Medellín, Colombia

2015

“Un amigo mío, el más inofensivo soñador que haya existido jamás, prendió una vez fuego a un bosque, para ver, según decía, si el fuego se propagaba con tanta facilidad como suele afirmarse. Diez veces seguidas fracasó el experimento; pero a la undécima hubo de salir demasiado bien.”

Charles Baudelaire

Agradecimientos

A mi familia por su apoyo incondicional, por tener fe en mí, por respetar las decisiones que he tomado en mi vida y convencerme de que tengo un futuro brillante por delante.

A la profesora Gloria Patricia Jaramillo, directora de esta tesis, quien me brindó todo su conocimiento, experiencia y apoyo para sacar adelante este trabajo; siempre con una actitud alegre y cordial que me motivaron a dar lo mejor de mí.

Al profesor Santiago Arango, por ver potencial en mí, acogerme bajo su tutoría y contribuir a mi crecimiento como profesional y como persona.

A mis compañeros de trabajo, especialmente a Jessica Arias y Luisa Díez, quienes con sus aportes y ayuda contribuyeron al desarrollo de esta investigación, e hicieron este largo camino más agradable y llevadero.

A mis amigos, con quienes pasé los mejores momentos de mi vida, y sin los que no hubiera podido llegar a ser la persona que soy hoy en día.

Resumen

La calibración de modelos en Dinámica de Sistemas mejora el ajuste entre los datos simulados por el modelo y los datos históricos, aumentando la confianza en ellos y la representatividad de los sistemas reales. En años recientes el proceso de calibración se ha visto potenciado por la automatización y la implementación de algoritmos de optimización en los programas de simulación. Esto ha permitido que el proceso se realice en tiempos relativamente cortos y por cualquier persona, incluso sin conocimientos en el proceso de calibración; lo que ha llevado a que el proceso se realice en ocasiones de forma descuidada, dejando de lado elementos como la selección de la función objetivo o la definición de los métodos de optimización. En esta tesis se evalúan tres métodos de optimización metaheurística; uno basado en algoritmos genéticos, uno basado en el algoritmo de Powell y un tercer algoritmo mixto para la calibración de modelos en Dinámica de Sistemas. La evaluación se hizo con el desempeño en la calibración de los modelos medidos por el error cuadrático porcentual de los datos, el error máximo alcanzado en el tiempo de simulación y el coeficiente de ajuste R^2 , además un estudio cualitativo y descriptivo mediante análisis de la distribución del error y los coeficientes de Theil. Como resultado se encuentra que los métodos de optimización permiten obtener un mayor ajuste entre los datos históricos y los datos observados por el modelo, mejorando cada uno de los criterios mencionados. Este proceso se puede realizar con relativa facilidad y rapidez dada la inclusión de los algoritmos en los programas de simulación. Sin embargo, estos son sensibles a la forma en la que se realiza el proceso y al método de optimización empleado, presentando diferencias entre los valores arrojados por cada uno de los métodos como se espera para modelos con complejidad dinámica.

Palabras clave: Calibración, Dinámica de Sistemas, Optimización Metaheurística, Algoritmos Genéticos, Algoritmo de Powell.

Abstract

Calibration of models in System Dynamics improves the fitting between simulation results and historical data, increasing the confidence of the model and the representativeness of the real system. Recently, the calibration process has been potentiated by automation and optimization methods, both embedded in simulation software. Given the easiness, modelers have let the calibration process unattended, usually ignoring fundamental elements such as objective function, or definition of the optimization method. In this thesis we evaluate three metaheuristic optimization methods for calibration in System Dynamics: the first one based on genetic algorithms, the second one based on Powell's algorithm, and a mixed third one. We used three criteria for evaluating the performance of each method: square percentage error of data, maximum error during simulation, and adjustment coefficient R^2 . Additionally, we performed a qualitative and descriptive analysis through error distribution and Theil coefficients. As a result, we found that the three optimization methods allow a better adjustment between historical data and simulation models, by improving all the mentioned criteria. The calibration process can be easily performed given the inclusion of optimization methods in simulation software. However, results are sensitive to the selected method and the calibration process followed by the modeler. Such sensitivity was observed in the differences among each method's results. This is expected given the dynamic complexity in System Dynamics models.

Keywords: Calibration, System Dynamics, Metaheuristic Optimization, Genetic Algorithms, Powell's Algorithm.

Contenido

1.	Marco teórico	3
1.1	Dinámica de Sistemas.....	3
1.2	Calibración	6
1.2.1	Los parámetros de calibración	7
1.2.2	La función objetivo	8
1.2.3	El método de optimización.....	10
(a)	Algoritmo de Powell.....	11
(b)	Algoritmos genéticos	13
(c)	Algoritmos híbridos	15
2.	El problema de investigación	16
2.1	Antecedentes	16
2.2	Descripción del problema	18
2.3	Objetivo general	19
2.4	Objetivos específicos	19
3.	Metodología	20
3.1	Selección de métodos de optimización:.....	20
3.2	Selección de modelos	24
3.2.1	Modelo de electrificación en USA:	24
3.2.2	Modelo de sustitución de fuentes energéticas:	26
3.3	Selección de función objetivo	28
3.4	Criterios de evaluación	29
3.4.1	Reducción en la función objetivo	30
3.4.2	Valor máximo del error.....	30
3.4.3	Coeficiente R^2	31
3.4.4	Distribución del error.....	31
3.4.5	Coeficientes de Theil	31
3.5	Construcción de los modelos.	31
3.6	Recopilación de la información.....	32
3.7	Análisis y comparación de los datos.....	32
4.	Resultados.....	34
4.1	Calibración del modelo de electrificación.....	34
4.1.1	Evaluación cualitativa de los resultados en el modelo de electrificación.	35
4.1.2	Evaluación cuantitativa de los resultados en el modelo de electrificación.	39
(a)	Función objetivo.....	39
(b)	Valor máximo del error.....	40
(c)	Coeficiente R^2	41
(d)	Coeficientes de Theil	42
4.1.3	Resultados con búsqueda no guiada en el modelo de electrificación.....	44

(a)	Función objetivo	44
(b)	Valor máximo del error.	46
(c)	Coeficiente R^2	47
(d)	Coeficientes de Theil.....	48
4.2	Calibración del modelo de sustitución de fuentes energéticas.	50
4.2.1	Evaluación cualitativa de los resultados en el modelo de sustitución.....	52
4.2.2	Evaluación cuantitativa de los resultados en el modelo de sustitución.	57
(a)	Función objetivo	57
(b)	Valor máximo del error.	58
(c)	Coeficiente R^2	59
(d)	Coeficientes de Theil.....	60
4.2.3	Resultados con búsqueda no guiada en el modelo de electrificación.	62
(a)	Función objetivo	62
(b)	Valor máximo del error.	64
(c)	Coeficiente R^2	65
(a)	Coeficientes de Theil.....	66
5.	Conclusiones y recomendaciones	69
5.1	Cumplimiento de los objetivos.....	73
5.2	Recomendaciones y trabajo futuro.....	74

Lista de figuras

	Pág.
Figura 1-1: Proceso de modelado en Dinámica de Sistemas.	5
Figura 1-2: Proceso del algoritmo de Powell en dos dimensiones.	12
Figura 1-3: Diagrama del proceso general de los algoritmos genéticos.	15
Figura 3-1 Configuración de T1, Algoritmo de Powell en Vensim	22
Figura 3-2: Configuración de T2, Optquest de Palisade empleado en un modelo en Excel.	23
Figura 3-3: Configuración de T3, Algoritmos genéticos en PowerSim.	23
Figura 3-4: Diagrama de flujos y niveles del modelo de electrificación.	25
Figura 3-5: Modulo base de la capacidad del gas natural para el modelo de sustitución.	27
Figura 3-6: Módulos comunes a todas las fuentes en el modelo de sustitución.	28
Figura 3-7: (Izq) Diferencia entre los datos iniciales y los datos históricos (der) Diferencia entre los datos del modelo calibrado y los datos históricos.	33
Figura 3-8: Diferencia entre la serie de datos iniciales y la serie de datos luego del proceso de calibración.....	33
Figura 4-1 Simulación de la variable Vivienda del modelo de electrificación.....	36
Figura 4-2: Simulación de la variable Población del modelo de electrificación.....	36
Figura 4-3: Valores de la función objetivo para T1 para el modelo de electrificación.	37
Figura 4-4: valores de la función objetivo para T3 para el modelo de electrificación.....	38
Figura 4-5: Valores de la función objetivo para T2 para el modelo de electrificación	38
Figura 4-6: Simulación de la demanda de gas natural del modelo de sustitución.	52
Figura 4-7: Simulación de la demanda de carbón del modelo de sustitución.	53
Figura 4-8: Simulación de la demanda de Energías renovables no convencionales del modelo de sustitución.....	53
Figura 4-9 Simulación de la demanda hidroeléctrica del modelo de sustitución.....	54
Figura 4-10: Simulación de la demanda de petróleo del modelo de sustitución.	54
Figura 4-11: Valores de la función objetivo para T1 para el modelo de sustitución.....	55
Figura 4-12: Valores de la función objetivo para T2 para el modelo de sustitución.	56
Figura 4-13: Valores de la función objetivo para T3 para el modelo de sustitución.....	56

Lista de tablas

	Pág.
Tabla 3-1: Nomenclatura de los métodos empleados.....	22
Tabla 3-2: Comparación de los modelos escogidos.	24
Tabla 4-1. Valores iniciales de los criterios del modelo de electrificación.	35
Tabla 4-2. Valores de la función objetivo del modelo de electrificación calibrado.....	40
Tabla 4-3. Distribución de la función objetivo en el modelo de electrificación calibrado. .	40
Tabla 4-4. Valores máximo del error del modelo de electrificación calibrado.	41
Tabla 4-5. Valores del coeficiente R^2 del modelo de electrificación calibrado.....	42
Tabla 4-6. Estadísticos de Theil para el modelo de electrificación calibrado.	43
Tabla 4-7: Posición de los métodos según su desempeño en los criterios.	43
Tabla 4-8: Valores de la función objetivo del modelo de electrificación calibrado sin guía de expertos.	45
Tabla 4-9 Diferencias entre los valores de la función objetivo del modelo de electrificación obtenidos sin guía de expertos en comparación con la calibración con guía de expertos.	45
Tabla 4-10. Distribución de la función objetivo en el modelo de electrificación calibrado sin guía de expertos.....	46
Tabla 4-11. Valores máximo del error del modelo de electrificación calibrado sin guía de expertos.....	47
Tabla 4-12. Valores del coeficiente R^2 del modelo de electrificación calibrado sin guía de expertos.....	48
Tabla 4-13 Diferencias entre los valores del coeficiente R^2 del modelo de electrificación	48
Tabla 4-14. Coeficientes de Theil para el modelo de electrificación calibrado sin guía de expertos.....	49
Tabla 4-15. Diferencias entre los coeficientes de Theil del modelo de electrificación.....	49
Tabla 4-16. Posición de los métodos según su desempeño en los criterios en la búsqueda sin guía de expertos.	50
Tabla 4-17. Valores iniciales de los criterios del modelo de electrificación.	51
Tabla 4-18 Valores de la función objetivo del modelo de sustitución calibrado.....	57
Tabla 4-19. Distribución de la función objetivo en el modelo de sustitución calibrado.	58
Tabla 4-20. Valores máximo del error del modelo de sustitución calibrado.	59
Tabla 4-21. Valores del coeficiente R^2 del modelo de sustitución calibrado.	60
Tabla 4-22. Coeficientes de Theil para el modelo de sustitución calibrado.....	61
Tabla 4-23 Valores de la función objetivo del modelo de sustitución calibrado sin guía de expertos.....	63

Tabla 4-24. Distribución de la función objetivo en el modelo de sustitución calibrado sin guía de expertos.....	64
Tabla 4-25. Valores máximo del error del modelo de sustitución calibrado sin guía de expertos.	65
Tabla 4-26. Valores del coeficiente R^2 del modelo de sustitución calibrado sin guía de expertos.	66
Tabla 4-27 Coeficientes de Theil para el modelo de sustitución calibrado sin guía de expertos.	67

Introducción

Uno de los principales fines del modelado en Dinámica de Sistemas (DS) es lograr una representación apropiada del sistema estudiando, de forma que se pueda alcanzar un mayor entendimiento de su comportamiento y tener una idea de los efectos que se podrían tener al intervenir el sistemas con políticas (Barlas, 1996). De esta manera, una representación precisa del sistema real es siempre deseable ya que, además de aumentar la confianza en el modelo, brinda validez a las conclusiones y resultados obtenidos del mismo (Bailey, Bras, & Allen, 1998; Dangerfield & Roberts, 1996). Así, se busca que un modelo tenga el comportamiento correcto (replicación histórica) por las razones correctas y así, entre mayor sea la coherencia entre los datos simulados por el modelo y los datos reales/históricos, mayor será la confianza que se tendrá en el modelo.

La calibración es un proceso que permite estimar parámetros del modelo con valor desconocido o con incertidumbre. Esto se hace mediante un ajuste entre el comportamiento observado y el comportamiento simulado (Oliva, 2003; Rahmandad, Oliva, & Osgood, 2015); de esta forma, se mejora la precisión y representatividad del modelo. Sin embargo, la implementación de técnicas de optimización automáticas ha llevado a que los modeladores realicen este proceso forma rápida y en ocasiones sin toda la formalidad requerida (Oliva, 2003), sin prestar atención al diseño del proceso. Esta situación puede ocasionar que se fuerce en algunas ocasiones el modelo y se obtengan buenos resultados por las razones equivocadas. (Barlas, 1996). Múltiples autores, como Dangerfield & Roberts (1996) y Kelojarhu & Wolstenholme (1988), han propuesto guías sobre los aspectos principales a tener en cuenta cuando se lleva a cabo un proceso de calibración. En este sentido se estudian diferentes elementos como la selección de parámetros, la definición de una función objetivo que mida el error de los datos o los métodos de optimización (Vanni, Karnon, & Madan, 2011). En el caso de este último elemento, los autores sugieren emplear algoritmos metaheurísticos dada la complejidad y dinámica de los sistemas estudiados con DS. Sin embargo, y aunque en la literatura se sugiere que se debe seleccionar el método de optimización apropiado para

cada problema (X. Yang, 2013), no existe una referencia sobre qué tipo de algoritmo se debe emplear según las características de los modelos en dinámica de sistemas, por lo que se sugiere que se comprueben los resultados empleando diversos métodos de optimización (Vanni et al., 2011). Adicionalmente, se tienen limitaciones computacionales puesto que los programas de simulación cuentan con un único algoritmo, lo que implica que el modelador debe invertir tiempo y esfuerzo en traducir su modelo a otros lenguajes de programación. Tampoco se cuenta con literatura que permita ver un indicio sobre las diferencias de los efectos de diferentes metaheurísticas en el proceso de calibración, la mayoría de los estudios en el área de optimización en dinámica de sistemas se centran recientemente en la forma de calcular el ajuste de los modelos, diseño de funciones multiobjetivo o con incertidumbre, o emplear optimización para el diseño de políticas.

El presente trabajo busca estudiar la incidencia de la selección de método optimización en el ajuste de los datos simulados del modelo y los datos históricos y analizar sus ventajas y desventajas. Para esto se hace la aplicación de tres diferentes métodos de optimización metaheurística en el proceso de calibración de dos modelos de dinámica de sistemas diferentes. El documento se desarrolla de la siguiente forma: primero se presenta un capítulo con los conceptos teóricos asociados al estudio, en donde se presentan generalidades del área de estudio (dinámica de sistemas), los conceptos básicos del proceso de calibración, así como los elementos principales de este; posteriormente se presenta un capítulo con la definición del problema, los antecedentes y el estado de arte del proceso de calibración, específicamente en Dinámica de Sistemas, además de los objetivos a alcanzar en el trabajo; después se describe el proceso que se llevó a cabo y las consideraciones metodológicas como la selección de los modelos, la selección de la función objetivo y los criterios para la evaluación de los métodos; finalmente se presentan los resultados obtenidos en la investigación para cada uno de los modelos estudiados, para dar paso a la sección de conclusiones y recomendaciones.

1. Marco teórico

En el presente capítulo se abordan las bases teóricas sobre las que se desarrolla el trabajo y se presentan generalidades sobre los conceptos utilizados a lo largo del mismo. El capítulo comienza con una introducción al área de conocimiento (dinámica de sistemas), donde se presentan las particularidades de la metodología de simulación y los sistemas abordados por esta, y posteriormente se explica el papel de la calibración dentro de los modelos de dinámica de sistemas así como sus principales elementos.

1.1 Dinámica de Sistemas

Dinámica de sistemas (DS) es una metodología asistida por computador utilizada para el modelamiento y aprendizaje en sistemas complejos (Duggan, 2008). Tiene sus orígenes en los años setentas, donde surge como una variación de la teoría de control aplicada al análisis de sistemas y problemas de gestión (Dangerfield & Roberts, 1996; Ponzo, Dyner, Arango, & Larsen, 2011), por lo que se considera tanto una metodología matemática como de simulación. Lo que diferencia a los modelos de DS de otros sistemas dinámicos no es la matemática detrás del modelo sino las especificaciones de las ecuaciones y el proceso de modelamiento (Sweeney & Sterman, 2000). Los modelos de DS son formulados mediante ecuaciones diferenciales representadas en flujos y niveles (los niveles son cantidades que pueden acumular masa o información, y los flujos son las variaciones de los niveles) que permiten estudiar el comportamiento de los sistemas dinámicos en un periodo determinado de tiempo (Sterman, 2002; Sweeney & Sterman, 2000), especialmente de aquellos caracterizados por relaciones de causalidad, ciclos de realimentación, no linealidades y la presencia de retardos al interior del sistema (Aracil, 1999; J. D. Morecroft, 1983; Sterman, 2002; Sweeney & Sterman, 2000). Dada la complejidad de dichas ecuaciones, éstas no poseen soluciones analíticas que se puedan obtener fácilmente (Aracil, 1999), por lo que se hace necesario la utilización de métodos numéricos para obtener una aproximación apropiada (Sweeney & Sterman, 2000).

Los modelos en DS destacan el comportamiento y las tendencias de los sistemas (Glover & Kochenberger, 2010), permitiendo tener una visión holística de los problemas construida a partir de la vinculación de patrones de conducta observables desde estructuras a nivel micro y los procesos de toma de decisiones dentro del sistema. De esta forma, se logra superar las limitaciones cognitivas para comprender la complejidad detallada de la situación problemática y hacer inferencias conductuales confiables (Oliva, 2003) para, posteriormente, elaborar políticas que mejoren el rendimiento dinámico del sistema con respecto a los objetivos establecidos (Eksin, 2009). De igual forma, la metodología de DS permite capturar los modelos mentales de expertos familiarizados con el sistema modelado, y llevarlos de un lenguaje “común/natural”-cualitativo a un objeto matemático –cuantitativo, haciendo uso igualmente de técnicas de modelado participativas a través de modelado en grupo (Morecroft, 1983; Sweeney & Sterman, 2000). Esto convierte a la DS no solo en una herramienta de soporte a la toma de decisiones sino, también, en una herramienta de aprendizaje en diferentes disciplinas. Dada su transversalidad, la DS permite simular problemas y el mecanismo de solución en contextos tales como ambientes sociales, administrativos, económicos, ecológicos, entre otros (Forrester, 1989; Sterman, 2000, Morecroft, 2007); o inclusive, abordar un mismo problema/sistema desde diferentes enfoques, centrándose en puntos relevantes para los decisores (Fleiter, Worrell, & Eichhammer, 2011).

El proceso de modelado en DS suele contener cuatro procesos básicos (Morecroft, 2007):

1. *Articulación del problema*, se identifica y analiza el problema a abordar, se definen los objetivos, el horizonte de tiempo de la simulación, las aplicaciones y el alcance del modelo.
2. *Formulación de la hipótesis dinámica*, se definen las variables endógenas y exógenas que intervienen en el problema, así como las relaciones entre ellas, que llevan a explicar el comportamiento del sistema dinámico.
3. *Formulación del modelo matemático*, la hipótesis dinámica se expresa en diagramas de flujos de niveles, llevando las relaciones de las variables a ecuaciones matemáticas.
4. *Validación*, se evalúa tanto la estructura como el comportamiento del modelo, enfocándose en su representación del sistema real.

5. *Simulación de políticas y estrategias*, se simulan diferentes escenarios futuros aplicando modificaciones en la estructura para eliminar comportamientos no deseados o favorecer situaciones convenientes.

El proceso de modelamiento en DS es iterativo y rizomático, es decir que no sigue una subordinación directa entre los pasos de modelamiento sino que cualquier elemento puede afectar o incidir en cualquier otro (ver figurar 1-1). Este tipo de proceso produce una retroalimentación entre cada uno de los pasos, lo que permite un ajuste y una validación parcial de la estructura y el comportamiento del sistema. Sin embargo, el ajuste que se da por la realimentación en el proceso de modelado es limitado dada la complejidad de los modelos y la falta de soluciones analíticas. Adicionalmente, en algunos casos los modelos elaborados se construyen sobre parámetros inciertos o parámetros que se deben estimar y verificar posterior a la construcción del modelo. Para estas situaciones se plantea un proceso complementario a los planteados por Morecroft denominado “*Calibración*”, que emplea técnicas de optimización para llevar a un nivel mayor de ajuste el modelo (Dangerfield & Roberts, 1996; Keloharju & Wolstenholme, 1988).

Figura 1-1: Proceso de modelado en Dinámica de Sistemas.
Adaptado de (J. Morecroft, 2007).



1.2 Calibración

Calibración se refiere al proceso mediante el cual se estiman parámetros (de los cuales se desconoce su valor o sobre los que existe incertidumbre o imprecisión) del modelo para obtener un ajuste entre el comportamiento observado (comportamiento real del sistema) y el comportamiento simulado (resultado de la estructura dinámica planteada en el modelo)(Oliva, 2003; Rahmandad et al., 2015). La calibración es un proceso complementario a los procesos básicos de DS, que se emplea para aumentar la precisión de los resultados arrojados por el modelo y aumentar la confianza en el mismo. Si bien durante el proceso de modelado en DS se realizan ajustes, dada la naturaleza rizomática del mismo, la calibración del modelo implica un estudio detallado de parámetros así como el uso de técnicas de optimización y se aplica luego de validar el modelo.

La calibración se enfoca directamente en el comportamiento del sistema, observando el modelo de forma agregada a través los resultados arrojados por las principales variables (outputs) como efecto de los valores asignados a los parámetros (inputs). La calibración no busca realizar cambios directos en la estructura del modelo y actúa como un proceso de “caja negra” en el que el modelo de simulación se convierte en una subrutina de un optimizador. Por esta razón, debido a que se ciñe a la estructura planteada y no realiza modificaciones a las ecuaciones del modelo, la calibración como proceso no se puede considerar como una prueba de validación de la estructura del mismo. Y si bien la calibración permite aumentar la validez de un modelo (Oliva, 2003) y mejorar su desempeño al generar con mayor precisión el comportamiento observado, trabaja sobre el supuesto de que la estructura del modelo es válida. En caso de que existieran dudas respecto a la validez de la estructura, la calibración contribuiría al encubrimiento de los errores de formulación y forzaría al modelo a generar resultados apropiados por razones incorrectas, degenerando el modelo (Oliva, 2003). Esto también puede ocurrir si se realiza el proceso de calibración bajo valores poco razonables de los parámetros, lo que suele ser producto del desconocimiento por parte del modelador del sistema modelado y sus límites, o del desconocimiento sobre el proceso mismo de calibración (Lyneis & Pugh, 1996; Oliva, 2003).

Con el fin de evitar errores en el proceso de calibración, múltiples autores (Dangerfield & Roberts, 1996; Keloharju & Wolstenholme, 1988) han abordado el tema de “*buenas prácticas*” en DS, enfocándose en tres elementos principales del proceso: el establecimiento de los parámetros a calibrar, la definición de la función objetivo (que valora de alguna manera la precisión de los resultados del modelo en comparación con los reales) y la selección de las estrategias de búsqueda o método de optimización (Vanni et al., 2011). A continuación se presenta una descripción de cada uno de estos elementos y se expone algunas consideraciones a tener en cuenta a la hora de realizar el proceso de calibración de modelos en DS.

1.2.1 Los parámetros de calibración

Los parámetros son elementos del modelo que suelen representarse como datos del sistema y no involucran operaciones matemáticas en sí mismos, aunque forman parte de otras variables y ecuaciones más complejas, teniendo una influencia en el estado inicial del sistema (parámetros de condiciones iniciales) o afectándolo en cada uno de los periodos de tiempo de la simulación. Los parámetros utilizados en el proceso de calibración suelen ser aquellos parámetros sobre los que no se tiene información concreta, ya sea porque no son observables directamente, porque se tiene un grado de incertidumbre sobre su valor o su concepto como tal es abstracto (Vanni et al., 2011). Mediante la calibración, se busca asignar a dichos parámetros el valor que permita un mayor ajuste entre los datos modelados y los valores reales de las variables principales.

Debido a que la calibración es un proceso de ajuste y estimación, se busca que el número de parámetros a calibrar sea el menor posible. Una gran cantidad de parámetros a estimar, reduce la confiabilidad del modelo al traducir grandes errores en pequeñas desviaciones de valores razonables que, junto a intervalos de confianza más amplios, hacen más difícil detectar errores fundamentales de formulación, sobre todo cuando se ha logrado un buen ajuste al comportamiento histórico (Oliva, 2003). Para evitar dicho comportamiento, es preciso realizar una selección precisa de los parámetros, comenzando por descartar aquellos

parámetros posibles de estimar de forma desagregada y directa con otros métodos confiables, o aquellos parámetros a los cuales el modelo y las variables principales sean insensibles.

Es preciso aclarar que, pese al desconocimiento del valor exacto, se debe realizar una estimación a priori de los parámetros. Dicho valor se usa como base en el modelo, y permite realizar la validación del mismo, aunque esté sujeto a modificaciones posteriores. El enfoque metodológico de la DS presupone que el modelador tiene los conocimientos y el entendimiento suficiente del sistema como para realizar un modelo preliminar (Keloharju, 1988), por lo que es posible asignar un valor inicial basado en conjeturas u opinión de expertos (Lyneis & Pugh, 1996). Adicionalmente, la calibración requiere que el modelador asigne un rango de posibles valores para cada uno de los parámetros (límites); estos se definen según el conocimiento que hay del sistema, tanto del modelador como de expertos, las condiciones intrínsecas de las variables, los límites propios del modelo (alcance del modelo) y la coherencia con la realidad (Dangerfield & Roberts, 1996; Keloharju & Wolstenholme, 1988). Los límites deben ser lo suficientemente amplios como para que el optimizador pueda explorar nuevas alternativas y no quedarse atrapado en óptimos locales (guiados posiblemente por los sesgos del modelador), pero deben ser lo suficientemente estrechos como para darle precisión, y una aproximación realista, a la estimación. Como estrategia de delimitación de parámetros, Dangerfield y Roberts (1996) sugieren crear límites estrechos inicialmente y expandirlos en caso de que se observe que estos restringen demasiado el rango de exploración.

1.2.2 La función objetivo

La función objetivo es una expresión matemática que resume el comportamiento general del modelo (Keloharju & Wolstenholme, 1988), plantea el objetivo a alcanzar por el optimizador (Eksin, 2009) y brinda información sobre el desempeño del modelo en términos de las variables de interés (Talbi, 2009). La

función objetivo se plantea sobre aquellas variables que guían el comportamiento general del sistema y que a su vez estén influenciadas por los parámetros a calibrar. En el caso de tener submodelos, es recomendable calibrarlos de forma parcial, y aislada, utilizando funciones específicas y los parámetros pertinentes.

Para el caso del proceso de calibración, la calidad de los valores se mide según el ajuste entre los datos reales y los datos simulados de las principales variables del modelo sobre las cuales recae el efecto de los parámetros de interés. Esta función objetivo es la que diferencia la calibración de otros procesos de optimización y suele estar asociada a funciones de error. En la literatura sobre estadística, comúnmente son usadas medidas como *mínimos cuadrados*, *chi cuadrado* (o ponderada de mínimos cuadrados) y *pruebas de máxima verosimilitud* (Rahmandad et al., 2015; Vanni et al., 2011). En el caso de mínimos cuadrados, el error se calcula como la sumatoria del cuadrado de la diferencia entre los datos reales y los output del modelo en cada uno de los periodos de simulación (ecuación 1-1); y el valor que mejor ajusta los datos es aquel que minimice dicha suma. El error absoluto se calcula de forma análoga, salvo que las diferencias se toman en valor absoluto y no se elevan al cuadrado (ecuación 1-2). Las medidas de mínimos cuadrados y error absoluto suelen aplicarse de forma intuitiva y no demandan información específica de los datos, como el caso de chi cuadrado y máxima verosimilitud que exigen independencia entre los datos y ajustes a distribuciones, así como información sobre la varianza de los mismos.

Ecuación 1-1: Cálculo del error cuadrático.

$$Error\ cuadrático = \sum_{i=0}^t (valor\ simulado_t - valor\ de\ referencia_t)^2$$

para cada periodo (t) del tiempo de simulación

Ecuación 1-2: Cálculo del error absoluto.

$$Error\ absoluto = \sum_{i=0}^t |valor\ simulado_t - valor\ de\ referencia_t|$$

para cada periodo (t) del tiempo de simulación

1.2.3 El método de optimización

En calibración el “*método de optimización*” se refieren al método utilizado para buscar (en el espacio establecido por los límites de los parámetros) los valores de los parámetros que producen los mejores resultados, coincidiendo con la meta especificada por la función objetivo (Vanni et al., 2011). Existen diversos métodos de optimización, pero la selección del método viene dada directamente por las características propias de cada uno de los problemas. Se recomienda el uso de métodos determinísticos o algoritmos de optimización exactos para problemas lineales con pocas restricciones, donde el espacio de búsqueda es limitado, o problemas extensos en los que se cuente con tiempo y recursos computacionales (X.-S. Yang, 2010). Se recomienda el uso de métodos metaheurísticos para el caso de problemas con grandes espacios de búsqueda, con gran cantidad de restricciones, problemas dinámicos, modelos no analíticos de problemas de optimización que no pueden ser resueltos de manera exhaustiva, problemas con incertidumbre o ambigüedades, que son difíciles de resolver por métodos exactos o generan un mayor coste computacional (X.-S. Yang, 2010). Este último es el caso de problemas en DS (caracterizados por una alta no linealidad, presencia de ciclos de realimentación y retardos), en los cuales usualmente no es posible llegar a soluciones analíticas e incluso el modelo más simple puede producir un comportamiento complejo a través de la gran variedad de dinámicas generadas en el proceso de optimización (McSharry, 2004; X.-S. Yang, 2010).

Talbi (2009), describe formalmente las metaheurísticas como “*un proceso de generación iterativo el cual es guiado por un proceso heurístico (proceso de sentido común para hallar una solución rápida a un problema) combinado inteligentemente con diferentes conceptos para exploración y explotación del espacio de búsqueda*”. Dicho proceso permite reducir el tiempo en el que se halla una solución factible, así como reducir los costos computacionales. De igual forma, la programación intrínseca del algoritmo le permite evitar problemas como el atasco en mínimos locales o dificultades en espacios discontinuos, que ocurren

cuando el modelo es complejo y no lineal. Aunque las metaheurísticas, a diferencia de los algoritmos de optimización exactos, no garantizan la obtención de soluciones óptimas (McSharry, 2004), ni define que tan cerca se encuentra de obtener el óptimo (Talbi, 2009), debido a que el algoritmo puede arrojar diferentes resultados cada vez que se corre debido la componente aleatoria de estos métodos y la búsqueda es sensible en algunos casos de los parámetros que define el modelador (McSharry, 2004).

Existen diferentes algoritmos metaheurísticos, en su mayoría inspirados en procesos naturales, los cuales varían según sus procesos de exploración y explotación. A continuación se explican de forma general las bases de los métodos empleados en el presente trabajo. Estos se seleccionaron por estar incluidos en los programas de simulación especializados en DS. Una descripción más detallada sobre la selección de los algoritmos se presenta en la sección 3.1. A continuación se muestran las generalidades de cada uno de los métodos de optimización

(a) Algoritmo de Powell

Este método es empleado en el software de simulación Vensim. El método de Powell, es un algoritmo hill-climbing que localiza el mínimo de una función f mediante búsquedas secuenciales unidimensionales. Es un método iterativo que no requiere de gradientes, por lo que sirve tanto para funciones diferenciables como no diferenciables. No requiere de métodos numéricos y por lo tanto su error de redondeo se reduce considerablemente. Para encontrar el mínimo de la función, el método de Powell aplica el concepto de direcciones conjugadas. Dichas direcciones son más efectivas como direcciones de búsqueda que otras, como pueden ser la búsqueda univariante o las direcciones ortogonales (Universidad de Alicante, n.d.).

Ecuación 1-4: Definición de la magnitud de búsqueda.

$$\Delta^n = [f(X_0^{n-1}) - f(X_0^n)]$$

Ecuación 1-5: Definición de las direcciones de búsqueda.

$$\mu = X_0^0 - X_0^n$$

Se evalúan los puntos de búsqueda:

Ecuación 1-6: Evaluación de los puntos de búsqueda.

$$f_0^1 = f(2X_0^n - X_0^0)$$

Y se llevan a cabo las comparaciones:

Ecuación 1-7: Comparación de los puntos de búsqueda.

$$\text{Si } f_i^0 \geq f(X_0^0) \text{ y/o } (f(X_0^0) - 2f(X_0^n) + f_i^0)(f(X_0^0) - f(X_0^n) - \Delta) \geq \frac{\Delta(f(X_0^0) - f_i^0)}{2}$$

Entonces la dirección μ no es una buena dirección de búsqueda y repetiríamos la búsqueda comenzando desde el punto X_0^n como punto base. En caso contrario se procede a incorporar la dirección μ al conjunto de direcciones de búsqueda, sustituyendo a la dirección que peor resultado hubiese obtenido. En la nueva etapa de búsqueda conviene que la última dirección investigada (en la etapa de búsqueda unidireccional) sea μ . Las dos desigualdades anteriores comprueban, la primera si se obtiene una mejora en la dirección al pasar del punto X_0^0 al punto X_0^n , y la segunda, que la función descienda de manera pronunciada y no a través de una zona plana.

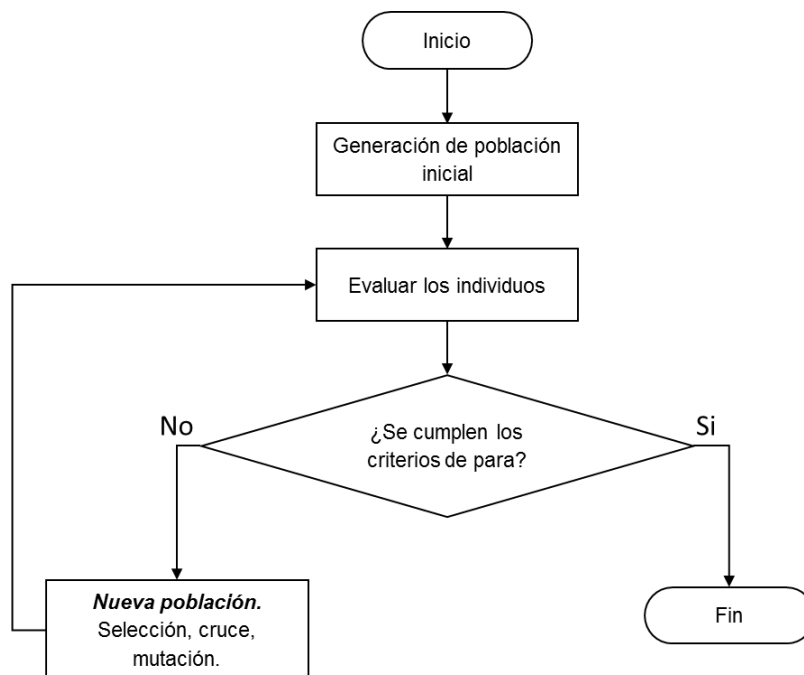
(b) Algoritmos genéticos

Los algoritmos genéticos (AG) son algoritmos de optimización basados en las ideas del proceso evolutivo de los seres vivos. Hacen uso de vectores de caracteres, denominados genes, donde cada componente representa un posible conjunto de valores. La principal idea detrás de los AG es la reproducción de la población, formada colectivamente por el conjunto de vectores. Partiendo de una población inicial, nuevas poblaciones se forman a través de algunas variaciones

análogas a los conceptos biológicos de reproducción: selección, recombinación y mutación por ejemplo. Este proceso permite una mayor exploración del espacio de búsqueda dada la evaluación simultánea de diversos puntos, y dado que no necesita conocimientos de la estructura propia del problema, reduce los costos computacionales.

El algoritmo comienza con una población inicial, definida aleatoriamente o a criterio del modelador. Luego un conjunto de individuos se selecciona para actuar como padres de la siguiente generación. La probabilidad de ser seleccionado es proporcional al ajuste individual. Estos padres, son emparejados para crear un nuevo conjunto de hijos. Con cierta probabilidad, algunos de los individuos pueden mutar. Luego la población actual es remplazada por sus descendientes. Si se aplica Elitismo, los mejores padres de la población actual no son remplazados (X.-S. Yang, 2010). En la figura 1-3 se muestra el proceso general empleado en AG. Para mayores detalles de la programación revisar (Schulz, 2006).

Los AG no requieren de conocimientos específicos sobre el modelo para realizar la búsqueda de óptimos, lo que funciona bien en modelos con gran cantidad de restricciones y dinámicas complejas (Glover & Kochenberger, 2010; Talbi, 2009; X. Yang, 2013). Adicionalmente, los AG operan globalmente, tomando información de varios puntos del espacio de búsqueda, permitiendo sobrepasar los límites locales y evadir problemas de discontinuidades en las funciones. Sin embargo, la aleatoriedad empleada en el algoritmo puede aumentar los tiempos de convergencia, dependiendo también de los parámetros empleados, el tamaño de la población, el número de iteraciones, entre otros (Glover & Kochenberger, 2010; Talbi, 2009; X. Yang, 2013).

Figura 1-3: Diagrama del proceso general de los algoritmos genéticos.

(c) Algoritmos híbridos

Se refieren a algoritmos compuestos por la fusión de dos o más algoritmos. El objetivo general de la hibridación es integrar las diferentes técnicas de exploración, aprendizaje y adaptación, así como las características ventajosa de cada uno de los métodos, para sobreponerse a las limitaciones individuales de los algoritmos y obtener mejores resultados, reduciendo el tiempo de búsqueda y mejorando la efectividad del algoritmo para encontrar una solución en el espacio de búsqueda (Talbi, 2009). Dada la complejidad y la gran cantidad de algoritmos existentes, no hay una forma estándar que defina la forma de integrar los algoritmos, y cada parametrización y especificación de la combinación de los algoritmos se considera como un híbrido. En el presente trabajo se emplea OptQuest que es un algoritmo híbrido resultado de la combinación entre Búsqueda tabú, programación entera, redes neuronales y búsqueda dispersa.

2.El problema de investigación

En este capítulo se presentan las antecedentes de la aplicación de optimización para la calibración de modelos en DS, los avances que se han realizado en este campo de estudio, así como los principales autores que han trabajado el tema. Posteriormente se presenta el estado actual del tema y las falencias encontradas para dar paso a la descripción detallada del problema de investigación y el planteamiento de los objetivos a alcanzar con el presente trabajo.

2.1 Antecedentes

Al igual que la DS, la Optimización como ciencia surge del estudio de servomecanismos en los años 30's y 40's; y desde un comienzo se han planteado como ciencias complementarias (Graham & Ariza, 2003). Pesé a esto, son limitados los estudios enfocados el uso de optimización en modelos de DS (Graham & Ariza, 2003). Al inicio de "System Dynamics Review" (1985-1989) se reportan cinco artículos relacionados con el tema (Graham & Ariza, 2003), de los cuales sobresalen los escritos por Keloharju, quien es considerado como uno de los pioneros en el estudio metodológico del uso de optimización en DS. Los primeros trabajos de Keloharju se enfocaron en el uso de métodos heurísticos para optimizar valores de parámetros de acuerdo a una cierta función objetivo (Eksin, 2009). Keloharju tomó un algoritmo heurístico de búsqueda de patrones (algoritmos Hill-climbing) y lo introdujo directamente en un lenguaje estándar de simulación en DS, como una subrutina del modelo; constituyendo lo que posteriormente sería el paquete computacional denominado DYSMOD (*Dynamic System Modeller, Optimizer and Developer*) (Dangerfield & Roberts, 1996). DYSMOD es usado en 1987 por Wolstenholme y Al-Alusi para la optimización de la estrategia de un ejército en un modelo de defensa (Eksin, 2009), y más adelante por Keloharju y Wolstenholme (1988)

para su artículo "*The use of optimisation as a tool for policy analysis and design in system dynamics models*", en el que se usa el "*Project Model*" desarrollado anteriormente por Richardson y Pugh (Duggan, 2008).

Luego de algunos años, Coyle (1998) retomó el estudio de los métodos de optimización en DS, planteando la discusión sobre cómo superar las debilidades de los algoritmos Hill-climbing (Eksin, 2009). Si bien, Coyle emplea en su trabajo el mismo algoritmo que Keloharju para hallar soluciones óptimas en modelos de DS (Duggan, 2008), busca mejorar los resultados del proceso de optimización empleando conjuntamente algunas "*buenas prácticas*" (Eksin, 2009), formulando cambios estructurales en los parámetros, además enfatizando en el papel de la optimización como una herramienta complementaria a los enfoques tradicionales en los estudios de sistemas dinámicos (Bailey et al., 1998).

A finales de los años 90's, Dangerfield & Roberts (1996) presentan una revisión general de las tácticas y estrategias para la optimización en DS. En dicho artículo se hace énfasis en la diferenciación del uso de métodos de optimización para el ajuste de datos históricos (calibración) y su uso para mejorar el proceso de diseño de políticas. Los autores, para ambos casos, utilizan un modelo de propagación del SIDA aplicando como heurística el algoritmo Hill-climbing (Eksin, 2009). Así mismo, Miller (1998) compara el valor de la población final (función objetivo) del modelo "*world 3*" utilizando como Metaheurísticas: búsqueda aleatoria, recocido simulado y algoritmos genéticos. (Eksin, 2009)

En estudios más recientes, Chen & Jeng (2004) y Grossman (2002) se centran en el estudio del uso de algoritmos genéticos para la optimización de políticas y describen las debilidades de los algoritmos tradicionales basados en gradientes (Duggan, 2008). Posteriormente, los esfuerzos en el campo de la optimización en DS se centran en el diseño de políticas para casos prácticos (Graham & Ariza, 2003; Oliva, 2003), aplicando criterios de optimización bajo múltiples objetivos (Duggan, 2008) y la construcción de parámetros con cierto nivel de incertidumbre (Ng, Sy, & Lee, 2012). Cabe resaltar el estudio de Eksin (2009), en el que se analiza el desempeño de la calibración de modelos en DS a través de variaciones en AG, aplicado a diferentes arquetipos de modelos; y el libro más reciente en DS "*analytical methods for dynamic modelers*" (Rahmandad et al., 2015) en el que se trabaja el tema de optimización de modelos pero enfocado en la

cuantificación del ajuste del modelo y algunas técnicas específicas para mejorar el desempeño de la optimización.

2.2 Descripción del problema

Los modeladores, tanto en DS como en otras áreas de simulación, se ven motivados no solo por producir un modelo adecuado de los sistemas, sino también por mejorar el desempeño de estos en algunos aspectos (Dangerfield & Roberts, 1996). Un modelo que replique de forma precisa el comportamiento histórico del modo de referencia, permite reforzar la confianza en el modelo por parte del cliente, por lo que es preferible a uno que no lo hace. De aquí que un mayor ajuste es deseado, y que los modeladores se interesen en procesos complementarios, como la calibración (Bailey et al., 1998; Dangerfield & Roberts, 1996).

El avance tecnológico y la disposición de nuevos paquetes de simulación amigables con el usuario, como Powersim y Vensim, ha llevado a automatizar el proceso de calibración, permitiendo tanto a expertos como inexpertos emplear este tipo de procesos, sin necesidad de comprender su trasfondo, y mejorar sus modelos con relativa facilidad (Oliva, 2003). Esto puede llevar a que el proceso de calibración se realice de forma descuidada, dejando a un lado análisis y aspectos importantes del proceso mismo como la selección de parámetros y algoritmos de búsqueda, obteniendo como resultado falsa confianza en los modelos.

Una de las formas de evitar dicho error, es emplear diferentes algoritmos de búsqueda, para corroborar el carácter óptimo de la solución, y superar falencias propias de la metaheurística (Vanni et al., 2011). Sin embargo, cada programa de simulación incorpora un único algoritmo (por ejemplo: AG para el caso de Powersim y algoritmo de Powell en Vensim) y este es el que se emplea en la calibración del modelo, lo que limita las alternativas de selección de métodos de optimización. De esta forma, la selección del método de optimización no atiende a los requerimientos del modelo para la calibración (¿cuál es el mejor algoritmo para el problema?(X. Yang, 2013)) sino a la selección inicial del programa de modelación, que es guiada principalmente por la familiarización del modelador con el programa. Lo que implica a su vez, que si un modelador desea

corroborar el ajuste realizado por el algoritmo de búsqueda, debe invertir tiempo y esfuerzo en traducir su modelo de un lenguaje a otro.

Sumado a lo anterior, pese a que la eficiencia de algoritmos como recocido simulado, AG o búsqueda aleatoria se han estudiado y comparado en diferentes contextos, pocos estudios se han realizado específicamente para modelos aplicados en DS (Eksin, 2009), lo que dificulta saber certeramente que tipo de metaheurísticas se debe utilizar según las características del modelo. Si bien Eksin, realiza un estudio sistémico de los efectos de los algoritmos en DS, se limita al estudio de GA. Lo que conlleva a la incertidumbre de cuál es el impacto real de los algoritmos de búsqueda en los resultados de la calibración de los modelos.

2.3 Objetivo general

Evaluar las ventajas y desventajas del uso de un conjunto de métodos de optimización meta-heurísticos para la calibración de modelos en dinámica de sistemas.

2.4 Objetivos específicos

- Identificar los elementos característicos principales del proceso de calibración en modelos de DS.
- Seleccionar, analizar y diferenciar varios métodos usados, o con potencial de uso, en la calibración de modelos de dinámica de sistemas.
- Proponer métricas que permitan evaluar el desempeño de diferentes métodos de optimización en la calibración de dos modelos de DS establecidos.
- Evaluar según los criterios planteados el desempeño de cada uno de los métodos de optimización en el proceso de calibración para los modelos seleccionados

3. Metodología

El principal objetivo del presente trabajo es explorar las diferencias en el ajuste logrado por diferentes métodos de optimización cuando son empleados para la calibración de modelos en DS. Para ello se siguieron los siguientes pasos:

1. Selección de los elementos de la calibración:
 - Modelos y parámetros.
 - Función objetivo.
 - Métodos de optimización.
 - Métricas para la comparación.
2. Construcción de los modelos.
3. Calibración los modelos con los diferentes métodos.
4. Recopilación de la información.
5. Análisis y comparación de los datos

A continuación se presenta la descripción detallada de cada uno de los elementos mencionados, y se especifican las razones para su elección:

3.1 Selección de métodos de optimización:

Se buscaron metaheurísticas incluidas en programas de simulación por la facilidad en el momento de aplicarlos a los modelos, y en concordancia con el problema y la practicidad del mismo, se seleccionan por ser los métodos principales a los que recurren los modeladores cuando desarrollan su modelo y piensan realizar un proceso de calibración. Con este criterio se resolvió utilizar los algoritmos utilizados en Powersim Studio10 y Vensim 6. El algoritmo base de Powersim se es AG, mientras que Vensim basa su algoritmo de optimización en el algoritmo de Powell. Adicionalmente a la disponibilidad,

se consideran estos algoritmos por ser uno de los primeros algoritmos desarrollados, ser bien conocidos y frecuentemente usados (Eksin, 2009)

También se selecciona OptQuest como método a estudiar. OptQuest es un algoritmo que se ha empezado a utilizar en los últimos años para optimizar en diferentes programas de simulación (como arena o simul8), por lo que es un referente de las técnicas actuales de metaheurísticas. Como algoritmo, OptQuest presenta una combinación entre búsqueda tabú, programación entera, redes neuronales y búsqueda dispersa (scatter search), aunque al igual que los otros dos métodos, no se conoce de primera mano la programación detallada. Pese a su difusión en el medio, no se encuentra dentro un programa especializado para DS, pero se puede emplear con Evolver (Palisade, 2014) para optimizar modelos programados en Excel.

Se aclara que el objetivo de la presente tesis no se centra en la construcción o configuración directa de los algoritmos, sino en los resultados arrojados por el proceso de calibración en general. Debido a esto se denominará T1 al proceso de calibración empleando algoritmo de Powell (Vensim), T2 al relacionado con OptQuest y T3 al referido a AG (Powersim), como se puede apreciar en la tabla 3-1. Adicionalmente, en las figuras 3-1 a 3-3 se observa la configuración de cada uno de los métodos de optimización cuando se emplean en cada uno de los programas de simulación. Aunque no es posible definir una equivalencia entre métodos (cuantos padres en AG equivalen a cuantas direcciones de búsqueda en el algoritmo de Powell por ejemplo), se definió que para todos los métodos se emplearía un máximo de mil iteraciones (máximo número de iteraciones Powersim) y una convergencia de 0.000000001.

Tabla 3-1: Nomenclatura de los métodos empleados.

Nomenclatura	Algoritmo Base	Programa de simulación	Descripción
T1	Algoritmo de Powell; Hill-climbing.	Vensim 6	Búsqueda unidireccional en cada variable para definir trayectoria de optimización.
T2	OptQuest: Búsqueda tabú, programación entera, redes neuronales y búsqueda dispersa.	Evolver de Palisade empleado en un modelo en Excel.	Combinación de metaheurísticas: Búsqueda tabú, programación entera, redes neuronales y búsqueda dispersa.
T3	Algoritmos genéticos	Powersim Studio 10	Vectores de caracteres que representan genes y simulan el proceso biológico de reproducción.

Figura 3-1 Configuración de T1, Algoritmo de Powell en Vensim

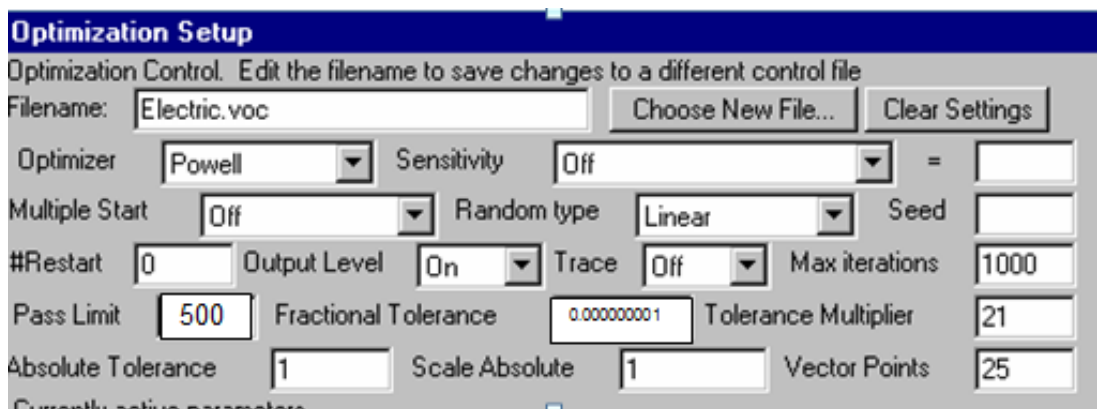


Figura 3-2: Configuración de T2, Optquest de Palisade empleado en un modelo en Excel.

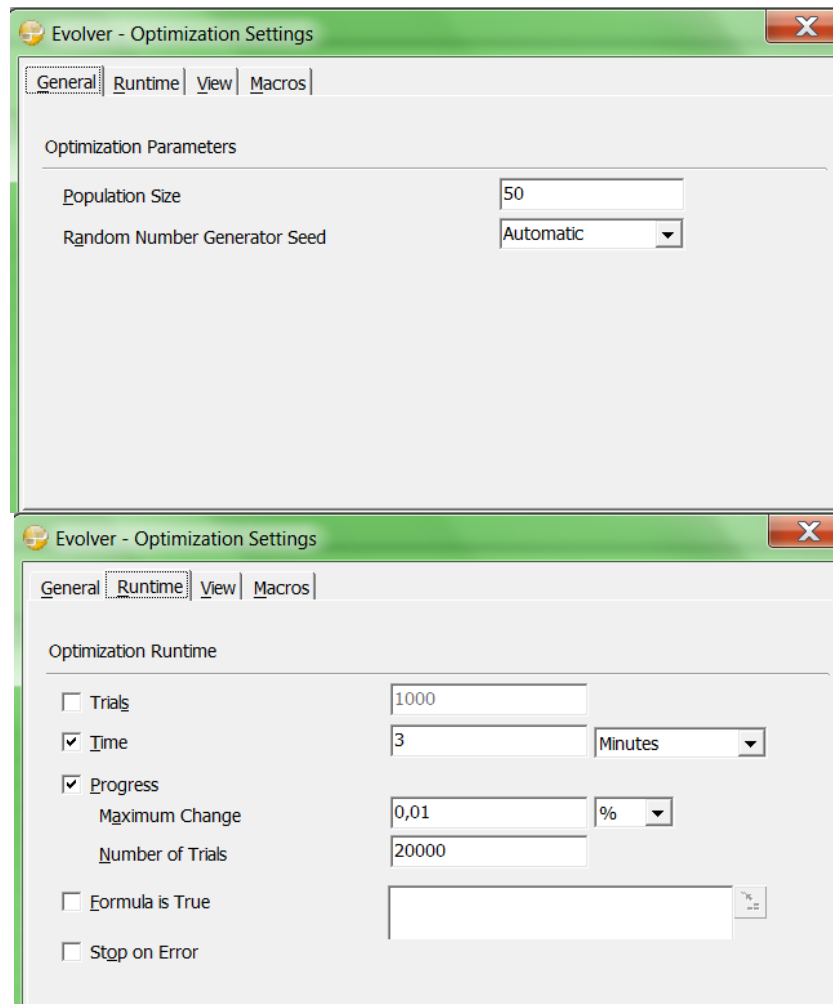


Figura 3-3: Configuración de T3, Algoritmos genéticos en PowerSim.

General

Specify settings for the Evolutionary Search Method used for the optimization.



Maximum generations:	Parents:	Offsprings:
1.000	3	15
Minimum convergence:	Seed:	
0.00000001	100	

3.2 Selección de modelos

Se buscaron modelos validados en los que se emplearan o se expresara la necesidad de realizar un proceso de calibración. Se buscaron modelos con una diferencia en la complejidad dinámica, en relación con el número de variables, submodelos y parámetros a calibrar. Como resultado se seleccionó el modelo de electrificación de viviendas en USA (VENTANA Systems inc, 2010) y el modelo de sustitución de fuentes energéticas para el caso de Chile (Rúa, 2014). En la tabla 3-2 se puede mirar de forma comparativa la diferencia de complejidad de los modelos.

Tabla 3-2: Comparación de los modelos escogidos.

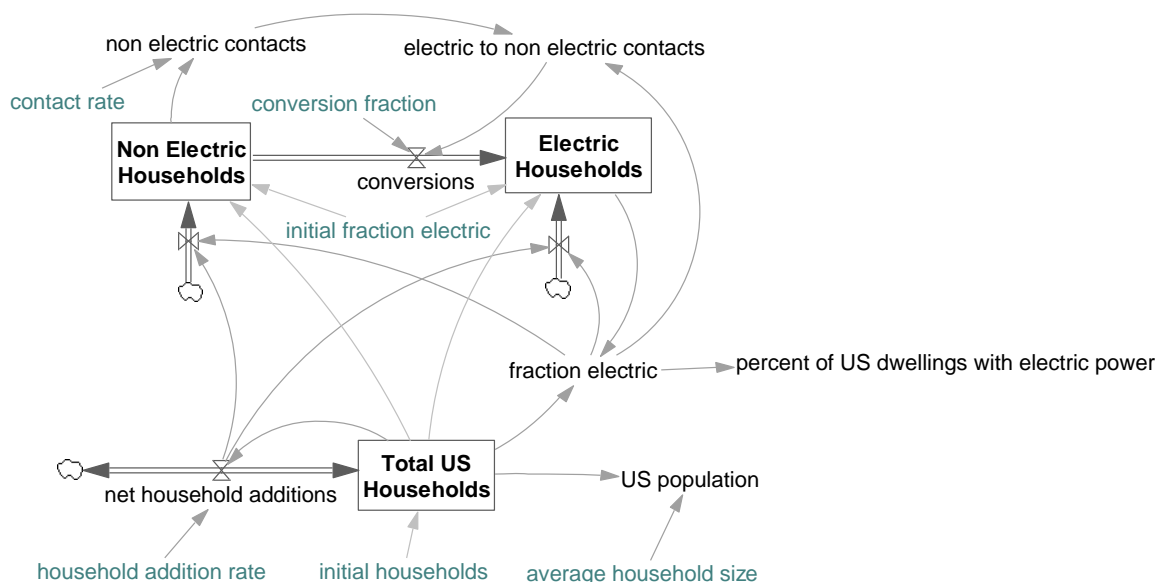
	Electrificación	Sustitución
Descripción	Modelo de difusión de Bass para simular la dinámica de electrificación de hogares en Estados Unidos	Estudia el desarrollo de capacidad instalada de cada una de las fuentes y la decisión de inversión en capacidad nueva, la cual se establece según los costos y un modelo Logit.
Variables	20	115
Variables de nivel	3	10
Parámetros a calibrar	4	16
Variables respuesta	2	5

A continuación se detallan los principales aspectos de cada modelo:

3.2.1 Modelo de electrificación en USA:

Este modelo aplica los conceptos del modelo de difusión de Bass para simular la dinámica de electrificación de hogares en Estados Unidos. En este se simula como, poco a poco, los hogares no conectados se van uniendo gradualmente a la red eléctrica hasta llegar a un estado donde la electrificación del sector es completa. En la figura 3-1 se muestra la imagen del modelo completo.

Figura 3-4: Diagrama de flujos y niveles del modelo de electrificación.



El modelo cuenta con veinte variables, de las cuales tres son niveles (Número de hogares electrificados, hogares sin electrificar y la población total) y cinco son parámetros (ver anexo A). Los parámetros sobre los que se tienen incertidumbre son: el número inicial de hogares, la fracción inicial de hogares electrificados, la tasa de adición de nuevos hogares y el efecto que lleva a los hogares no electrificados a adoptar la tecnología. Para poder realizar la calibración de estos modelos se tiene como referencia los datos históricos del porcentaje de viviendas con energía eléctrica (medidos como valores entre 0 y 1) y de la población (número de habitantes). Estas dos variables son las que conformarán la función objetivo total que se menciona en la sección 3.3.

Este modelo viene incluido como modelo básico en Vensim. Es un modelo simple, dado el número de variables y ciclos, que es usado para introducir a los nuevos modeladores en el proceso de la calibración de modelos. Dado que es un modelo diseñado para probar la calibración de modelos, cuenta con información y es claro respecto a los pasos de construcción del mismo.

3.2.2 Modelo de sustitución de fuentes energéticas:

El modelo elaborado por Moxnes (1990), muestra la dinámica de sustitución entre carbón, gas y aceite en la generación de energía en Europa. El modelo se centra principalmente en la capacidad instalada de cada una de las fuentes, así como la decisión de inversión en capacidad nueva, la cual se establece según los costos asociados a la fuente de energía y un modelo Logit, empleando como variables exógenas el precio y la demanda de cada una de las fuentes. Este modelo fue adoptado por Rua (2014) para estudiar el caso de la matriz energética de Chile, incluyendo como fuentes: carbón, gas, petróleo, energía hídrica y otras energías renovables.

El modelo cuenta con aproximadamente 115 variables. Está dividido por módulos según cada una de las fuentes y un módulo general en el que se comparan las cinco fuentes para realizar la distribución de las nuevas inversiones (ver anexo B). En las Figuras 3-2 y 3-3, se muestran el esquema general del modelo, del módulo para el caso particular del Gas Natural y los módulos comunes para todas las fuentes. Cada fuente tiene como niveles principales la capacidad instalada en equipos nuevos y la capacidad instalada en equipos viejos, lo que hace un total de diez variables de nivel. Adicionalmente, se tienen parámetros inciertos, que se calibraron para hallar su valor, estos son: valor inicial de la capacidad instalada de equipos nuevos y de equipos viejos para cada fuente, el parámetro alfa del modelo Logit y una variable denominada “*premium*” que simula los incentivos del gobierno por cierta fuente de energía. Como variables de control, que conforman la función objetivo, para el proceso de calibración se tienen los datos históricos de la demanda de cada una de las fuentes (expresados en Mtoes), y por consiguiente la demanda de energía total, como respuestas a la capacidad de generación en cada uno de los periodos t de la simulación.

Figura 3-5: Modulo base de la capacidad del gas natural para el modelo de sustitución.

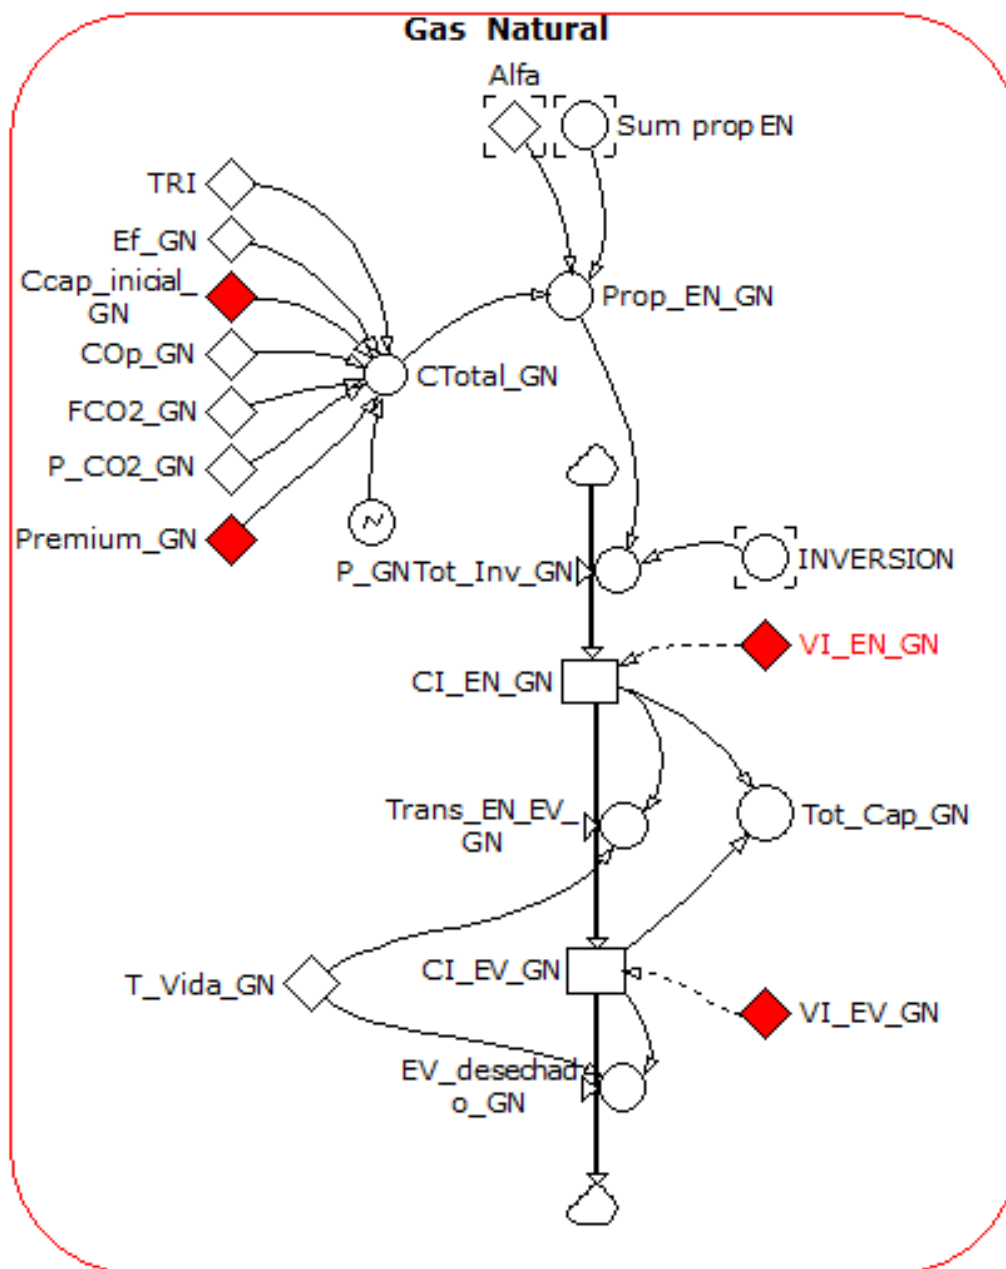
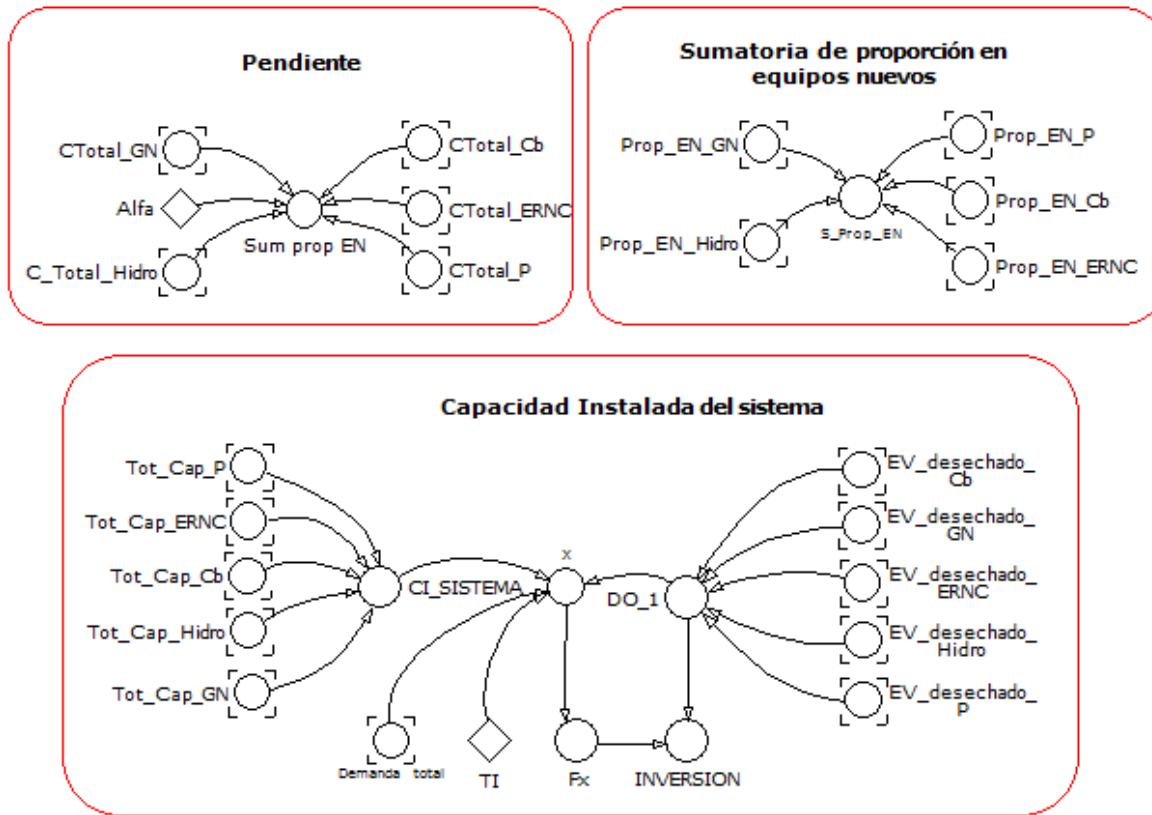


Figura 3-6: Módulos comunes a todas las fuentes en el modelo de sustitución.



3.3 Selección de función objetivo

Inicialmente se descartan las medidas de chi cuadrado y máxima verosimilitud, por exigir independencia entre los datos, condición que no se cumple con los modelos por la relación entre variables, donde el valor en el tiempo t depende del estado en el $t-1$, asemejando los datos a una serie de tiempo (Rahmandad et al., 2015). El error absoluto evita que errores negativos (por debajo del valor real) compensen errores positivos (por encima del valor real), al igual que el valor cuadrático, aunque este último penaliza en mayor medida los valores más alejados del valor real. Como criterios de error son apropiados de forma individual, pero dado que las variables y los resultados son diferentes en cuanto a dimensión y unidades, es necesario seleccionar una función objetivo para modelos multiobjetivo. En el caso de la guía de usuario de Vensim, se emplean pesos para equilibrar los tamaños numéricos de ambas variables (el porcentaje de viviendas y el número de habitantes), asignándoles valores aproximados a la

desviación estándar del error de predicción según la confianza en los datos y las unidades de medida. Si bien esta aproximación es válida, exige un alto grado de confianza en los datos, de lo cual se carece, especialmente en el modelo complejo, por ser información de fuentes secundarias. Por tal motivo se decidió emplear una variación del error cuadrático, que denominaremos error cuadrático porcentual, en el que se presenta la diferencia del error simulado como una proporción del error real (ecuación 3-1). Este nuevo cálculo del error, permite eliminar la diferencia de dimensiones entre las fuentes, y no presenta sesgos por intervención del modelador como lo hacen los pesos de ponderación. Complementariamente, en el anexo C se muestra una comprobación preliminar en el que se observa el desempeño del error cuadrático, el error absoluto y el error cuadrático porcentual.

Ecuación 3-1: Cálculo del error cuadrático porcentual.

Error cuadrático porcentual

$$= \sum_{i=0}^t \left[\frac{\text{valor simulado de } a_t - \text{valor de referencia de } a_t}{\text{valor de referencia de } a_t} \right]^2 + \sum_{i=0}^t \left[\frac{\text{valor simulado de } b_t - \text{valor de referencia de } b_t}{\text{valor de referencia de } b_t} \right]^2$$

para cada periodo (t) del tiempo de simulación, siendo a y b las variables respuesta del modelo.

El error cuadrático porcentual es adimensional, dado que normaliza las variables y las expresa en términos de una proporción. Esto permite incluir diferentes variables con diferentes dimensiones (como el porcentaje de viviendas electrificadas y el número de habitantes en el modelo de electrificación) en una misma función, y penaliza aquellos valores simulados que se encuentran más alejados del valor de referencia. De igual forma, el factor cuadrático elimina la polaridad de los errores, por lo que la función encuentra su mínimo en cero y es este el que define el nivel de ajuste cuando se minimiza.

3.4 Criterios de evaluación

Debido a las condiciones de los programas de simulación que limitan el seguimiento del proceso interno de las metaheurísticas, el presente trabajo se enfoca a un estudio offline

de los efectos del uso de cada uno de los métodos, es decir, el trabajo se enfoca principalmente en el ajuste y el resultado del modelo al final de la aplicación del algoritmo y no durante su ejecución. Los criterios seleccionados para evaluar el proceso de calibración son: Reducción en la función objetivo (error cuadrático porcentual), diferencia máxima que se alcanza en los periodos t de la simulación, Coeficiente R^2 . Adicionalmente se observa la participación de cada variable en la función objetivo, así como los coeficientes de error de Theil, para analizar las variaciones en las razones del error. A continuación se realiza una descripción de cada uno de los criterios y su relevancia para el estudio.

3.4.1 Reducción en la función objetivo

La función objetivo se encarga de definir el estado del sistema y define la meta a alcanzar para el optimizador (referencia). Es el referente de calidad que se emplea en el proceso de calibración, y es por lo tanto el criterio principal y el que evalúa directamente la mejora en el ajuste. Este valor se calcula al final de la simulación como la sumatoria de la diferencia cuadrática porcentual entre el valor simulado y el valor de referencia en cada uno de los periodos de simulación. Si bien se esperaría que un modelo que simule fielmente los datos reales obtenga como resultado valores cercanos a cero, esto es difícil de lograr en la práctica (Sterman, 2002). Asumiendo que el valor inicial (el que se presenta en la simulación original) de la función objetivo es aceptable (dado que el modelo está validado), y al no ser posible definir un límite máximo para el error, en el presente estudio medimos el desempeño del método como la diferencia entre dicho valor inicial y el valor final de la función objetivo una vez realizada la optimización.

3.4.2 Valor máximo del error

Es el mayor error cuadrático porcentual que se alcanza en alguno de los periodos de la simulación. Al igual que la función objetivo, es adimensional y no posee un límite máximo, pero su valor ideal es cercano a cero. Este criterio no otorga información respecto a la distribución de los errores en cuanto a varianza y media, pero permite definir el límite superior en el que se puede encontrar cualquier error en la simulación. Si bien un rango alto puede ser debido a puntos extremos o atípicos, es preferible un modelo con un valor máximo menor.

3.4.3 Coeficiente R^2

Muestra la proporción de la varianza de los datos simulados que puede atribuirse a la varianza de los datos históricos. Muestra que tanto representa el modelo el comportamiento real del sistema, en una escala de cero a uno (uno significa que los datos son explicados completamente por el modelo).

3.4.4 Distribución del error

Como tal no es un criterio que permita mostrar si el modelo mejora o empeora en términos de ajuste ya que no existe una proporción a priori que se pueda definir como óptima. Este criterio tiene un fin comparativo ya que permite analizar cuáles variables desempeñan un rol más importante y observar si los métodos de optimización muestran preferencia por el ajuste de alguna de las variables en particular.

3.4.5 Coeficientes de Theil

Estos coeficientes desagregan el error cuadrático medio (MSE por sus siglas en inglés) en tres diferentes fuentes de error: el error de media, el error de varianza y el error de correlación que, en conjunto, deben sumar una unidad. Los cálculos de cada uno de los coeficientes se observan en el anexo D. Ya que la función objetivo seleccionada es el error cuadrático porcentual y no el MSE, no es apropiado hacer inferencias directas sobre los resultados aplicando este criterio, pero los coeficientes de Theil permiten realizar un seguimiento a las fuentes de error y determinar si hay una mejora en el ajuste cuando el error se enfoca en los errores de varianza y correlación (Sterman, 1983).

3.5 Construcción de los modelos.

Cada uno de los modelos descritos se desarrollaron en los programas de simulación PowerSim, Vensim y, para poder aplicar Optquest, se replicó también el modelo en Excel. Se revisó que el método de integración en los tres programas fuera Euler (PowerSim y Vensim exigen que sea este para poder realizar optimización) y que los resultados arrojados en el caso inicial fueran lo más similares posibles. Una vez verificada la funcionalidad de los modelos se procedió a realizar la calibración en cada uno de los programas.

3.6 Recopilación de la información.

Debido a la componente aleatoria que presentan los métodos metaheurísticos es posible obtener diferentes resultados cada vez que se aplique el método de optimización. Por tal motivo se realizaron inicialmente diez corridas de cada uno de los métodos de optimización (se calibraron diez veces cada modelo) y se definió con un error del 10% la desviación de los datos y un nivel de confianza del 0.99 si la muestra era representativa o se necesitaba aumentar el número de corridas. Luego, se halló el promedio de las corridas y se tomó este resultado como el referente de cada uno de los procesos de calibración (T1, T2, T3) para cada modelo.

3.7 Análisis y comparación de los datos.

Al aplicar el proceso de calibración se tienen tres series de datos a comparar en cada modelo: La serie de datos históricos o de referencia, la serie de datos asociado al modelo inicial (sin calibrar) y la serie de datos resultado de la calibración del modelo. Como no se tiene control directo de la programación interna de los programas de simulación y de las metaheurísticas, se pretende realizar una comparación entre la relación de la serie inicial respecto a los datos históricos (figura 3-7 Izq) y la relación entre la serie de datos calibrados respecto a los datos históricos (figura 3-7 Der). En este sentido se asume que ha habido una mejoría debido al proceso de calibración si la diferencia entre los datos calibrados y los datos históricos es menor que la diferencia entre los datos iniciales y los datos históricos. Dicha diferencia se puede apreciar en la figura 3.8.

Figura 3-7: (Izq) Diferencia entre los datos iniciales y los datos históricos (der) Diferencia entre los datos del modelo calibrado y los datos históricos.

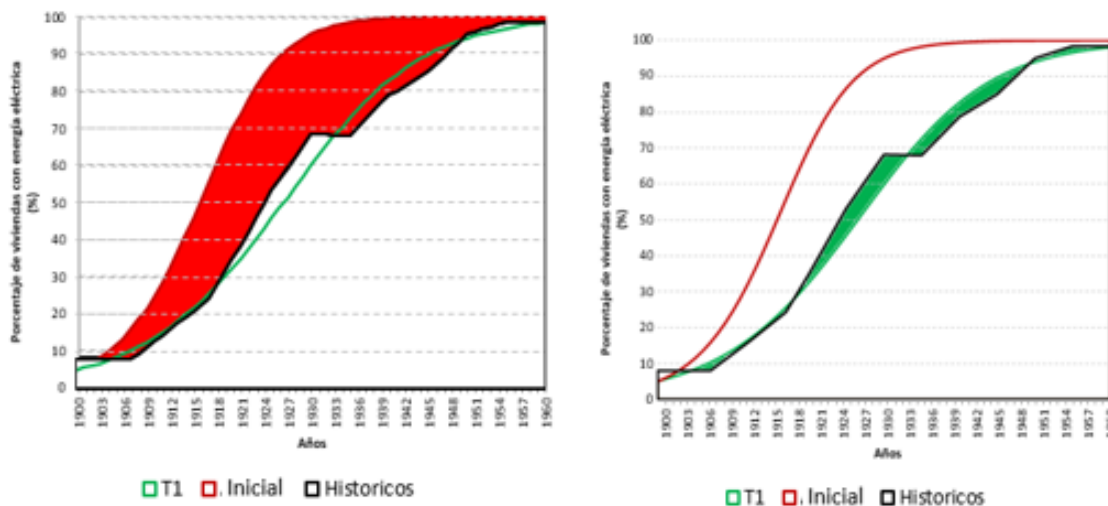
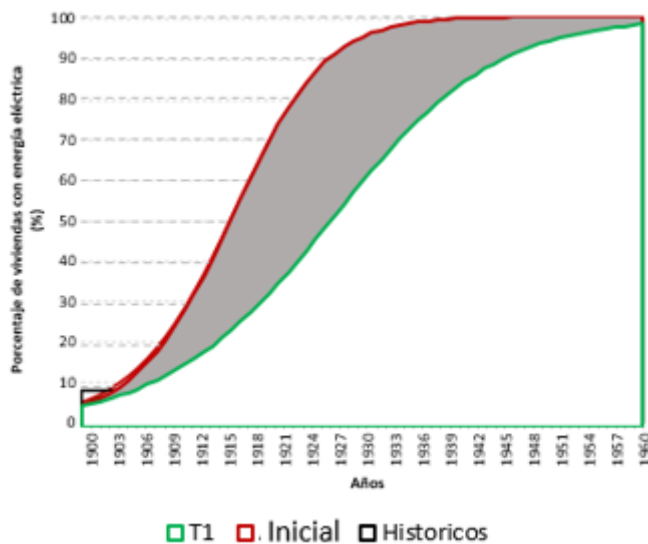


Figura 3-8: Diferencia entre la serie de datos iniciales y la serie de datos luego del proceso de calibración



Adicionalmente, se realiza un estudio sobre el proceso de optimización cuando no se conocen aproximaciones de los valores de los parámetros. En este caso, se llevan los valores de los parámetros a ceros o al valor mínimo permitido por el modelo, antes de realizar la calibración. De igual forma se realiza el proceso para diez diferentes corridas para cada uno de los métodos y se comparan los resultados con el promedio de estas.

4. Resultados

En este capítulo se presentan los resultados obtenidos de la calibración de los modelos empleando los métodos seleccionados y siguiendo los pasos del marco metodológico. Se presentan inicialmente los resultados para el modelo de electrificación, y posteriormente el modelo de sustitución, mostrando los valores de los criterios en el modelo original (sin calibrar), luego los resultados del modelo calibrado con cada uno de los métodos, junto con su comparación respecto a los valores iniciales del ajuste. Por último se muestran los resultados de los modelos cuando se emplea una búsqueda sin la guía de expertos, es decir, cuando no se tiene una estimación inicial de los parámetros sino que se comienza la calibración de los parámetros con valores iguales a los límites mínimos o cero.

4.1 Calibración del modelo de electrificación

El ajuste del modelo se hace variando los parámetros: número inicial de hogares, fracción inicial de hogares electrificados, tasa de adición de nuevos hogares y el efecto que lleva a los hogares no electrificados a adoptar la tecnología; ajustando los datos simulados e históricos del porcentaje de viviendas electrificadas (que se denominará desde este punto Viviendas) y la variable asociada al número de habitantes (que se denominará Población). En la tabla 4-1 se presenta un resumen de los criterios de evaluación obtenidos en el último periodo de simulación para el caso del modelo original (estado inicial). Estos valores son la base de comparación con la cual se evaluarán las mejoras en el modelo una vez se apliquen los métodos de optimización. Se trabaja con seis cifras decimales debido a que la dimensión de la población es de millones de habitantes, por lo que se considerará una diferencia significativa si se tiene una variación de 0.000001. Para el caso de Viviendas dado que es un porcentaje (con valores entre 0 y 100) se asumirá que existe una diferencia significativa a partir de 0.0001.

Tabla 4-1. Valores iniciales de los criterios del modelo de electrificación.

Los valores de la simulación original (sin calibración) de cada uno de los criterios de evaluación para las dos variables respuestas.

	Viviendas	Población	Total
Error cuadrático porcentual	23.1913681	4.6101043	27.8014724
Error máximo	1.66646433	0.2216400	
Distribución del error	0.83417769	0.1658223	
R²	0.86736975	0.9877908	

A continuación se presentan los resultados del modelo de electrificación cuando se aplica el proceso de calibración, tanto en la búsqueda con valores iniciales dados por expertos y como cuando no se tiene la guía de estos. Se realiza una descripción general de los resultados obtenidos, una evaluación cualitativa del proceso y una comparación con los criterios del modelo inicial presentados en la tabla 4-1.

4.1.1 Evaluación cualitativa de los resultados en el modelo de electrificación.

Las figuras 4-1 y 4-2 muestran los valores de las variables respuestas (Viviendas y Población) a lo largo del periodo de simulación para el caso de la simulación original, los datos históricos y la simulación con los parámetros calibrados con cada uno de los métodos de optimización. Los datos de la simulación del modelo calibrado corresponden al promedio de las corridas realizadas con cada uno de los métodos de optimización. Visualmente se aprecia una mejora en el ajuste para ambas variables debido a la reducción entre la distancia de los datos simulados y los datos históricos, pero no se logra observar una diferencia significativa entre los resultados arrojados por cada uno de los métodos, cuyas curvas se sobrepone en varios de los periodos de simulación.

Figura 4-1 Simulación de la variable Vivienda del modelo de electrificación.

Datos de la variable vivienda en todos los periodos de simulación para el caso de los datos históricos, la simulación original y cada uno de los modelos calibrados.





Figura 4-2: Simulación de la variable Población del modelo de electrificación.

(Datos de la variable población en todos los periodos de simulación para el caso de los datos históricos, la simulación original y cada uno de las simulaciones optimizadas)



Complementariamente, durante el proceso de calibración se percibe que los tiempos de optimización son relativamente cortos, con los equipos utilizados, varían entre 30 y 180 segundos, y la convergencia de las soluciones se da en pocas iteraciones. Para el caso de T1 el programa no presenta variaciones significativas respecto a diferentes corridas o cambios en la raíz generadora de números aleatorios y en general se obtiene una convergencia dentro de las primeras 500 iteraciones, que permanece hasta la próxima condición de parada (tiempo o máximo de iteraciones) como lo muestra la Figura 4-3. Por su parte, T3 ofrece una mayor variedad respecto a la aleatorización y a la posibilidad de soluciones, aunque los resultados suelen converger a un valor similar luego de 300 iteraciones (Figura 4-4). T2 es el más diverso de los métodos con mayores diferencias en los recorridos de los algoritmos, aunque es el que más tiempo emplea para hallar una solución y muestra una mayor diferencia en el valor de la función objetivo hallada, lo que se observa en la Figura 4-5.

Figura 4-3: Valores de la función objetivo para T1 para el modelo de electrificación.

Datos de la función objetivo durante las iteraciones del proceso de optimización empleando el método T1.




Figura 4-4: valores de la función objetivo para T3 para el modelo de electrificación.

Datos de la función objetivo durante las iteraciones del proceso de optimización empleando el método T3 para 10 corridas.

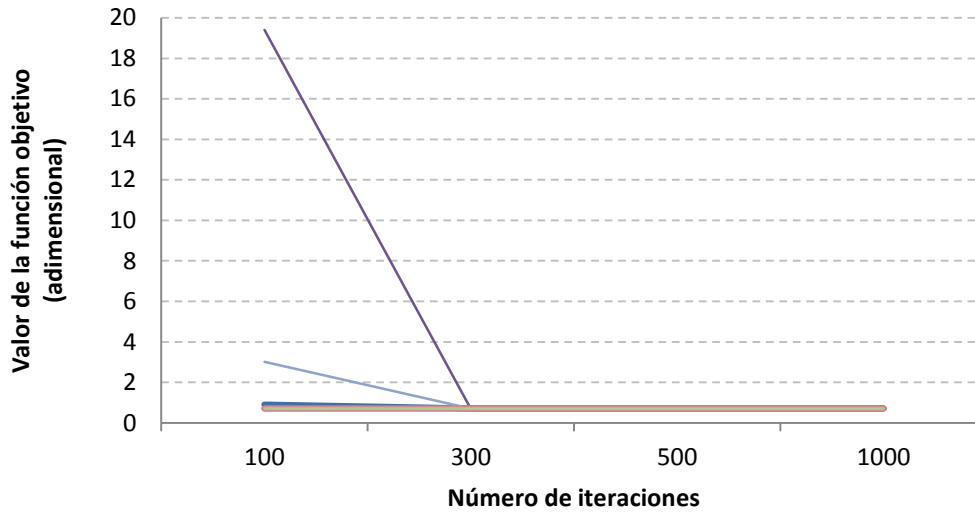
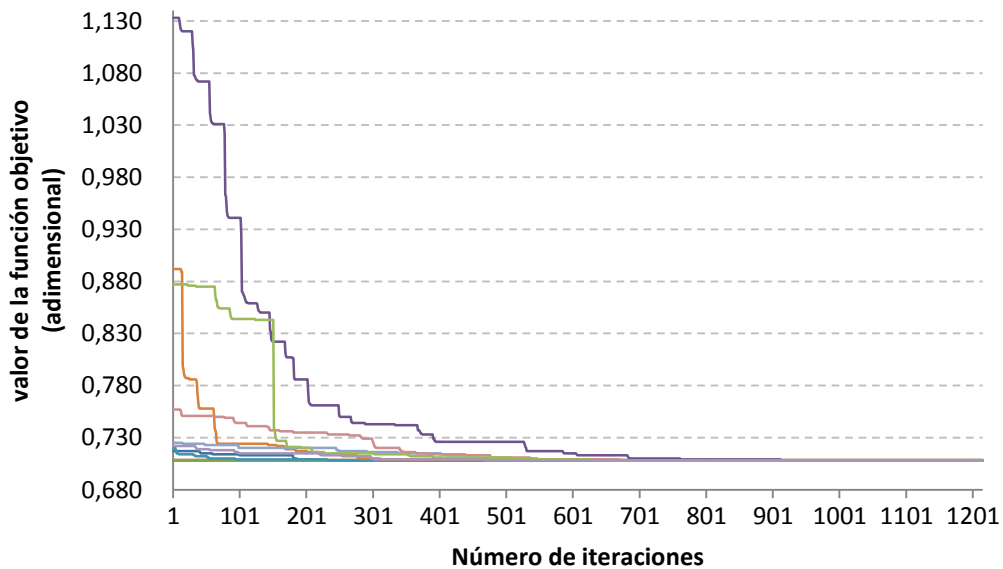


Figura 4-5: Valores de la función objetivo para T2 para el modelo de electrificación

Datos de la función objetivo durante las iteraciones del proceso de optimización empleando el método T2 para 10 corridas.



Los datos obtenidos en las Figuras 4-3 y 4-4, relativas a los métodos T1 y T3 se obtuvieron realizando simulaciones parciales, pausando el algoritmo en ciertos puntos de control (dividiendo el número de iteraciones máximos en cinco para obtener una visión general del proceso), ya que los programas asociados no permiten hacer seguimiento del algoritmo implementado y los valores alcanzados internamente para llegar al valor óptimo, lo que evitaba un rastreo de las soluciones y verificación posterior de los resultados.

4.1.2 Evaluación cuantitativa de los resultados en el modelo de electrificación.

(a) Función objetivo

En la Tabla 4-2 se presentan los valores del criterio de la función objetivo (error cuadrático porcentual) para el modelo calibrado con los métodos de optimización y la mejoría porcentual que se alcanza en comparación con el ajuste de la simulación inicial. Los tres métodos presentan una mejoría del ajuste respecto al modelo sin calibrar, reduciendo la función objetivo por encima del 97%, aunque existen diferencias entre los resultados arrojados por cada método. El método que presenta la mayor reducción de la función objetivo es T2, que alcanza un valor de 0.708133, lo que representa una reducción de 97.452895% respecto al ajuste inicial; lo sigue T3 con un valor de 0.708151 (reducción del 97.452830%) y de último se encuentra T1 con un valor de 0.715605 (reducción del 97.426016%). Analizando individualmente las variables, se observa que dicha posición se conserva para el caso de la variable Población pero se modifica para el caso de la variable Vivienda. En las Viviendas T3 presenta el mejor ajuste reduciendo la función objetivo en 97.067381%, seguido de T2 con 97.067379% y T1 con 97.058627%. En este criterio, T1 se encuentra dominado por los otros dos métodos, presentando una diferencia de 0.002029, 0.005443 y 0.007472 por encima de T2 (el mejor método) para las variables Viviendas, Población y la función objetivo respectivamente.

Tabla 4-2. Valores de la función objetivo del modelo de electrificación calibrado.

Valores de la función objetivo total y de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores

Método	Criterio	Viviendas	Población	Total
T1	Valor de la función objetivo	0.682145	0.033461	0.715605
	Variación porcentual	-97.058627%	-99.274184%	-97.426016%
T2	Valor de la función objetivo	0.680116	0.028018	0.708133
	Variación porcentual	-97.067379%	-99392258%	-97.452895%
T3	Valor de la función objetivo	0.680115	0.028036	0.708151
	Variación porcentual	-97.067381%	-99391856%	-97.452830%

Además del valor de la función objetivo, en la tabla 4-3 se muestra la proporción de cada una de las variables en la función objetivo con cada uno de los métodos de optimización. En todos los métodos se obtiene un aumento en la proporción del error de la variable viviendas, con una reducción de la misma dimensión en la variable población. Se observa que el método con menor rendimiento en la función objetivo total (T1) es el que presenta un menor aumento en la proporción de las viviendas en comparación con los demás métodos, con una diferencia inferior a 0.01.

Tabla 4-3. Distribución de la función objetivo en el modelo de electrificación calibrado.

Proporción de la función objetivo que pertenece a cada una de las variables respuesta. Se presentan los valores iniciales y la variación una vez se calibra el modelo. Las flechas indican si incrementa o si disminuye.

Método	Viviendas	Población
Inicial	0.834177	0.165823
T1	↑0.953241	↓0.046758
T2	↑0.960434	↓0.039565
T3	↑0.960409	↓0.039590

(b) Valor máximo del error.

Para el criterio de valor máximo del error, se presentan los resultados de la calibración con cada uno de los métodos en la tabla 4-4. Coherente con los resultados de la función objetivo, los resultados del valor máximo también se reducen con todos los métodos de optimización en comparación con el modelo sin calibrar. En este caso las reducciones en

la variable Vivienda son superiores al 91%, mientras que en la variable población superan el 98%. Aunque, y en contraste con los resultados de la función objetivo, T1 obtiene la mayor reducción en este criterio para ambas variables con valores de 0.130307 para Viviendas y 0.001973 para Población. En este caso T3 supera a T2 en el valor error máximo de las Viviendas, con un valor de 0.135602 frente a 0.135611; pero T2 supera a T3 en el caso de la población, presentando un valor de 0.002871 frente a 0.002930 del método T3. Complementando con el análisis de la distribución, se podría decir que para este criterio T3 sería mejor que T2, debido a que tiene un mejor desempeño en la variable viviendas en la que se encuentra concentrada la mayoría del error como se muestra en la **tabla 4-3**.

Tabla 4-4. Valores máximo del error del modelo de electrificación calibrado.

Valores de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores.

Método	Criterio	Viviendas	Población
T1	Error máximo	0.130307	0.001973
	Variación porcentual	-92.180627%	-99.109623%
T2	Error máximo	0.135611	0.002871
	Variación porcentual	-91.862388%	-98.704832%
T3	Error máximo	0.135602	0.002930
	Variación porcentual	-91.862893%	-98.677918%

(c) Coeficiente R^2

En relación al criterio del coeficiente R^2 , la **tabla 4-5** muestra los valores para cada uno de los métodos empleados y la variación porcentual tomando como referencia el ajuste inicial del modelo. La precisión con que el modelo explica los datos históricos se logra mejorar en un 13.9% para la variable Viviendas, así como un 0.4% en el caso de la Población. En la primera variable (Viviendas), el método que mejores resultados presenta es T2, con un valor de 0.988179, seguido por T3 con un valor de 0.988179 y T1 con 0.987995. Para la variable Población T3 alcanza un mayor valor 0.992278, por encima de T2 (0.992270) y T1 (0.992115). El ajuste para la Población es inferior al 1% debido al buen ajuste que presentaba la variable inicialmente, cercanos al valor máximo del criterio.

Tabla 4-5. Valores del coeficiente R^2 del modelo de electrificación calibrado.

Valores las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores.

Método	Criterio	Viviendas	Población
T1	Coeficiente R^2	0.987995	0.992115
	Variación porcentual	13.906975%	0.437783%
T2	Coeficiente R^2	0.988179	0.992270
	Error máximo	13.928276%	0.453448%
T3	Coeficiente R^2	0.988179	0.992278
	Error máximo	13.928270%	0.454312%

(d) Coeficientes de Theil

En la **tabla 4-6** se presentan la variación en los coeficientes de Theil para cada variable una vez se emplean los métodos de calibración. Para el caso de Viviendas, el error que se encontraba inicialmente concentrado en el promedio se traslada en su mayoría al error de correlación, con valores próximos a 0.966. Para esta variable la diferencia entre métodos se observa principalmente en los valores otorgados al error de promedio, si bien T2 y T3 tienen valores similares, T1 tiene un error de media de 0.012794 en comparación con valores cercanos a 0.0015 de los otros métodos. En la variable población, por su parte, se encuentra una mayor diferenciación entre métodos: T1 presenta un mayor valor tanto en la media como en la varianza, 0.062370 y 0.207288 respectivamente, por lo que se puede considerar peor que los otros métodos. En T3 el error se traslada en una mayor proporción a la correlación (0.992472) aunque el error remanente se reparte en proporciones similares entre el error de media (0.002544) y el error varianza (0.002882); a diferencia del T2 que enfoca el resto del error en el error de varianza con un valor de 0.006565, en comparación con un valor de 0.000963 del error de media.

Tabla 4-6. Estadísticos de Theil para el modelo de electrificación calibrado.

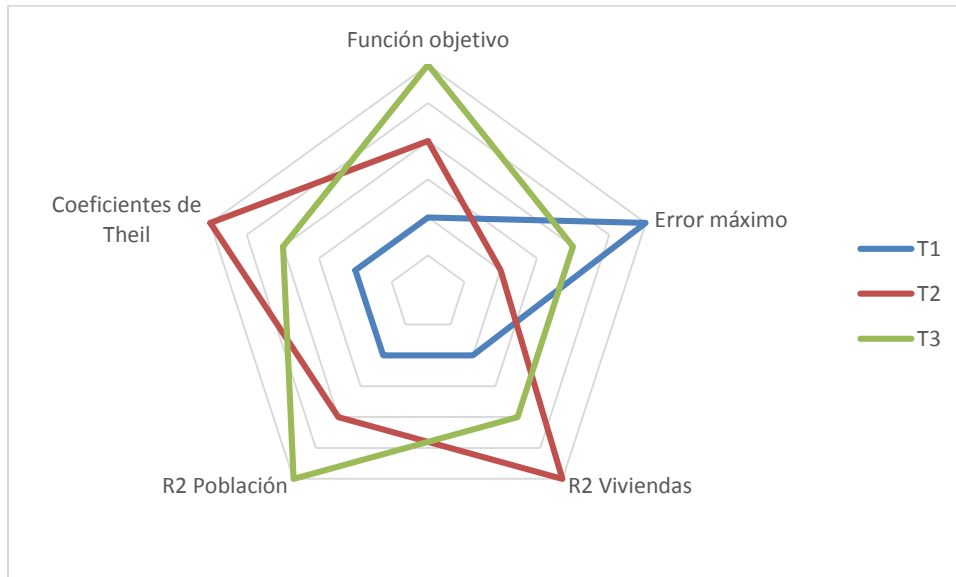
Proporción del error cuadrático distribuido entre el error de media, el error de varianza y el error de correlación para cada uno de las variables. Se muestra la proporción original (sin calibrar), el valor una vez calibrado y una flecha que muestra si aumenta o disminuye.

Método	Criterio	Viviendas	Población
Inicial	Media	0.654112	0.610330
	Varianza	0.002827	0.379026
	Correlación	0.343061	0.010644
T1	Media	↓0.012794	↓0.062370
	Varianza	↑0.020216	↓0.207288
	Correlación	↑0.966990	↑0.730342
T2	Media	↓0.001523	↓0.000963
	Varianza	↑0.032166	↓0.006565
	Correlación	↑0.966311	↑0.992472
T3	Media	↓0.001527	↓0.002544
	Varianza	↑0.032152	↓0.002882
	Correlación	↑0.966321	↑0.994574

En la tabla 4-7 se observa el orden de desempeño de cada método para cada uno de los criterios, siendo la posición “primero” para el mejor método y “tercero” para el peor. En general se aprecia que ninguno de los métodos es dominante para todos los criterios; si bien el método T1 se encuentra en última posición en la mayoría de criterios, se presenta como la mejor alternativa en el criterio de error máximo. El criterio del error máximo también permite discernir entre si T2 o T3 es mejor, en este criterio T2 se encuentra en la última posición, mientras que T3 se queda en el segundo puesto haciendo que este método se encuentre entre el primer o en el segundo puesto en todos los criterios.

Tabla 4-7: Posición de los métodos según su desempeño en los criterios.

	Primero	Segundo	Tercero
Función objetivo	T3	T2	T1
Error máximo	T1	T3	T2
R² Viviendas	T2	T3	T1
R² Población	T3	T2	T1
Coefficientes de Theil	T2	T3	T1

Figura 4-6: Posición de los métodos según su desempeño en los criterios

4.1.3 Resultados con búsqueda no guiada en el modelo de electrificación.

(a) Función objetivo

La **tabla 4-8** muestra los resultados para la función objetivo cuando se realiza una búsqueda no guiada (asignando valores de cero a los parámetros iniciales). Como se puede observar, los resultados presentan gran similitud con los obtenidos empleando un la búsqueda guiada por expertos, aunque existen diferencias que se presentan en la tabla 4-9. T3 obtiene el mejor resultado para la variable Vivienda, y no presenta diferencia respecto a la búsqueda de expertos. T2 sigue teniendo el mejor resultado, al obtener el mayor ajuste tanto en la variable población como en la función objetivo total, pese a tener un aumento en relación con la búsqueda con expertos. T1 continúa siendo dominada en este criterio por los demás métodos y es el que presenta una mayor variación en relación con la búsqueda por expertos. Aunque el método logra reducir en 0.00072 la función del error en la población, aumenta el error de la variable vivienda en 0.00736 cuando se realiza una calibración sin guía de expertos.

Tabla 4-8: Valores de la función objetivo del modelo de electrificación calibrado sin guía de expertos. Valores de la función objetivo total y de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores

Método	Criterio	Viviendas	Población	Total
T1	Valor de la función objetivo	0.6828811	0.032741	0.715622
	Variación porcentual	-97.055451%	-99.289794%	-97.425955%
T2	Valor de la función objetivo	0.6801157	0.028019	0.708135
	Variación porcentual	-97.067378%	-99.392212%	-97.452887%
T3	Valor de la función objetivo	0.6801146	0.028036	0.708151
	Variación porcentual	-97.067381%	-99.391856%	-97.452830%

Tabla 4-9 Diferencias entre los valores de la función objetivo del modelo de electrificación obtenidos sin guía de expertos en comparación con la calibración con guía de expertos.

Método	Viviendas	Población	Total
T1	0.000736	-0.000720	0.000017
T2	0.000000	0.000002	0.000002
T3	0.000000	0.000000	0.000000

La proporción de la función objetivo correspondiente a cada una de las variables se muestra en la **Tabla 4-10**, así como su diferencia respecto a los resultados arrojados por la búsqueda guiada por expertos. Coherente con los valores de la función objetivo presentados, la mayoría del error se traslada a la variable viviendas con valores superiores a 0.95. T3 no presenta diferencia respecto a la búsqueda de expertos, mientras que T1 aumenta adicionalmente un 0.001007 el error de las viviendas y T2 en 0.000003 el error de la población.

Tabla 4-10. Distribución de la función objetivo en el modelo de electrificación calibrado sin guía de expertos.

Proporción de la función objetivo que pertenece a cada una de las variables respuesta. Se presentan los valores iniciales y la variación una vez se calibra el modelo. Las flechas indican si incrementa o si disminuye

Método	Criterio	Viviendas	Población
Inicial	Proporción del error	0.834177	0.165823
T1	Proporción del error	↑0.954248	↓0.045752
	Diferencia con los expertos	0.001007	-0.001007
T2	Proporción del error	↑0.960432	↓0.039568
	Diferencia con los expertos	-0.000003	0.000003
T3	Proporción del error	↑0.960409	↓0.039591
	Diferencia con los expertos	0.000000	0.000000

(b) Valor máximo del error.

En relación al criterio de valor máximo, en la tabla 4-11 se presentan los valores del máximo error para el modelo calibrado sin guía de expertos. Al igual que en la función objetivo, las posiciones y las dimensiones se conservan respecto a la búsqueda guiada por expertos, aunque se presentan algunas diferencias. T1 tiene el menor error máximo con un valor de 0.129349 para la variable viviendas, el cual es 0.000958 menor que el obtenido por la búsqueda por expertos, y aunque aumenta el error en la población en 0.000053 sigue superando a los demás métodos. T2 aumenta el error en ambas variables pero la diferencia no es lo suficientemente grande para perder su posición frente a T3, que continua con un error de 0.002930 en la variable población.

Tabla 4-11. Valores máximo del error del modelo de electrificación calibrado sin guía de expertos.
 Valores de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores.

Método	Criterio	Viviendas	Población
T1	Error máximo	0.129349	0.002026
	Variación porcentual	-92.238144%	-99.085814%
	Diferencia con los expertos	-0.000958	0.000053
T2	Error máximo	0.135705	0.002911
	Variación porcentual	-91.856735%	-98.686555%
	Diferencia con los expertos	0.000094	0.000041
T3	Error máximo	0.135602	0.002930
	Variación porcentual	-91.862893%	-98.677918%
	Diferencia con los expertos	0.000000	0.000000

(c) Coeficiente R²

La tabla 4-12 presenta los valores del coeficiente R² obtenidos cuando se calibra el modelo sin la guía de expertos, y la tabla 4-13 presenta la diferencia de estos valores con los obtenidos por la calibración guiada por expertos. El coeficiente R² aumenta, obteniendo valores superiores a 0.98 para el caso de las Viviendas y superiores a 0.99 para el caso de población. Existe un aumento general del coeficiente en referencia a los resultados de la búsqueda con expertos; este se da en proporciones similares para todos los métodos por lo que no altera la posición o la preferencia por alguno de ellos. T1 aumenta en 0.005968 el coeficiente R² para las viviendas y 0.003940 para la población respecto a la calibración con expertos, pero aun con dicho aumento sigue siendo dominado en este criterio por los otros dos métodos.

Tabla 4-12. Valores del coeficiente R^2 del modelo de electrificación calibrado sin guía de expertos. Valores de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores.

Método	Criterio	Viviendas	Población
T1	Coeficiente R^2	0.987995	0.992115
	Variación porcentual	14.594997%	0.836667%
T2	Coeficiente R^2	0.988179	0.992270
	Variación porcentual	14.607725%	0.844133%
T3	Coeficiente R^2	0.988179	0.992278
	Variación porcentual	14.607664%	0.844403%

Tabla 4-13 Diferencias entre los valores del coeficiente R^2 del modelo de electrificación
Comparación de los resultados obtenidos con la búsqueda no guiada respecto a la búsqueda guiada por expertos

Método	Viviendas	Población
T1	0.005968	0.003940
T2	0.005893	0.003859
T3	0.005893	0.003853

(d) Coeficientes de Theil

En la Tabla 4-14 se observan los resultados de los coeficientes de Theil en la calibración sin guía de expertos. Los datos muestran, al igual que la búsqueda con expertos, que con los tres métodos el error tiende a concentrarse en el error de correlación, reduciendo el error de media. Tanto T2 como T3 aumentan el error de varianza en la variable Vivienda, aunque logran un error de media menor al de T1 que tiene un valor de 0.015662. De igual forma en el caso de la variable población, T1 disminuye el error de media y varianza pero aumenta solo el error de correlación a un valor de 0.754209, en comparación con valores de 0.993813 y 0.994574, de T2 y T3 respectivamente. En comparación con los resultados de la búsqueda guiada, T3 no presenta variaciones, T2 no presenta mejoras ya que aumenta el error de media en ambas variables, y T1 logra una mejoría al reducir el error de media en la variable viviendas pero aumenta en una mayor proporción el error de media de la población.

Tabla 4-14. Coeficientes de Theil para el modelo de electrificación calibrado sin guía de expertos.

Proporción del error cuadrático distribuido entre el error de media, el error de varianza y el error de correlación para cada uno de las variables. Se muestra la proporción original, el valor una vez calibrado y una flecha que muestra si aumenta o disminuye.

Método	Criterio	Viviendas	Población
Inicial	Media	0.654112	0.610330
	Varianza	0.002827	0.379026
	Correlación	0.343061	0.010644
T1	Media	↓0.015662	↓0.055000
	Varianza	↑0.018397	↓0.190790
	Correlación	↑0.965941	↑0.754209
T2	Media	↓0.001471	↓0.000933
	Varianza	↑0.032334	↓0.005254
	Correlación	↑0.966195	↑0.993813
T3	Media	↓0.001527	↓0.002544
	Varianza	↑0.032152	↓0.002882
	Correlación	↑0.966321	↑0.994574

Tabla 4-15. Diferencias entre los coeficientes de Theil del modelo de electrificación.

Comparación de los resultados obtenidos con la búsqueda no guiada respecto a la búsqueda guiada por expertos

Método	Criterio	Viviendas	Población
T1	Media	-0.002868	0.007370
	Varianza	0.001819	0.016498
	Correlación	0.001049	- 0.023867
T2	Media	0.000052	0.000030
	Varianza	-0.000168	0.001311
	Correlación	0.000116	- 0.001341
T3	Media	0.000000	0.000000
	Varianza	0.000000	0.000000
	Correlación	0.000000	0.000000

Como se puede observar en la Tabla 4-16, que resume el desempeño de los tres métodos en cada uno de los criterios de evaluación para la calibración no guiada por expertos, el punto de inicio de los parámetros no afecta las posiciones o las

preferencias por alguno de los métodos. Aunque si existe una diferencia entre los valores obtenidos.

Tabla 4-16. Posición de los métodos según su desempeño en los criterios en la búsqueda sin guía de expertos.

	Primero	Segundo	Tercero
Función objetivo	T3	T2	T1
Error máximo	T1	T3	T2
R² Viviendas	T2	T3	T1
R² Población	T3	T2	T1
Coefficientes de Theil	T2	T3	T1

Adicionalmente, como comentarios del proceso de calibración no guiada por expertos, se observó que el proceso de encontrar una solución óptima es rápido y corto, similar a la búsqueda guiada por expertos, la diferencia radica en los valores iniciales superiores, pero que se reducen en unas cuantas iteraciones (100 aproximadamente). De igual forma es necesario aclarar que cuando se le da el valor inicial de ceros a los parámetros de calibración es posible que surjan incoherencias en el modelo (valores sobre dimensionados, flujos negativos) o que eviten que se realice la simulación según el programa utilizado. T3 permite simular el modelo con inconsistencia en los valores, mientras que T2 advierte que los valores iniciales deben tener coherencia matemática para ser aplicado y exige que se corrija antes de optimizar el modelo, mientras que T1 simula el modelo para luego notificar el error. Esto puede tener complicaciones para los modeladores inexpertos en cuanto a la modelación o a la realización del proceso de calibración.

4.2 Calibración del modelo de sustitución de fuentes energéticas.

El modelo de sustitución empleado (Rúa, 2014) contempla cinco variables respuestas que corresponde a la demanda de cada una de las fuentes energéticas: Gas natural (GN), Carbón (Cb), Hidroeléctrica (H), Petróleo (P) y energías renovables no convencionales (ERNC). Si bien cada fuente tiene parámetros asociados (capacidad inicial de equipos viejos, capacidad inicial de equipos nuevos y el parámetro Premium) sobre los que se realiza el ajuste, la calibración se realiza en conjunto (variando todos los

parámetros al tiempo), ya que es un modelo de sustitución y el estado de todo el sistema es esencial para el desempeño de cada una de las fuentes. Todos los valores iniciales, se pueden observar en el anexo E. En la tabla 4-17 se presenta un resumen del estado inicial de los criterios de evaluación, y el ajuste que se tiene en el modelo original sin aplicar el proceso de calibración. Existen leves diferencias entre los estados iniciales de los modelos debido al programa de modelación empleado, por lo que los resultados se analizan en relación a la variación con respecto a los valores iniciales respectivos. Se trabaja con 6 cifras decimales dado que la dimensión de la variables resultantes se encuentran expresadas en Mtoes (1×10^6 Toes), por lo que en este caso se considerará una diferencia significativa si existe una variación de 0.000001.

Tabla 4-17. Valores iniciales de los criterios del modelo de electrificación.

Los valores de la simulación original (sin calibración) de cada uno de los criterios de evaluación para las dos variables respuestas.

	Criterio	GN	CB	ERNC	H	P	Suma
T1	<i>Función objetivo</i>	6.218408	2.277668	10.582950	2.540848	0.717175	6.218408
	<i>Valor Máximo del error</i>	0.804897	0.357394	0.906511	0.236019	0.077100	0.804897
	<i>Distribución del error</i>	0.278390	0.101968	0.473785	0.113750	0.032107	0.278390
	<i>Coefficiente R²</i>	0.602509	0.747714	0.593249	0.827997	0.871135	0.602509
T2	<i>Función objetivo</i>	6.218322	2.277488	10.582265	2.540831	0.717236	6.218322
	<i>Valor Máximo del error</i>	0.804805	0.357394	0.905800	0.236019	0.077113	0.804805
	<i>Distribución del error</i>	0.278397	0.101964	0.473773	0.113754	0.032111	0.278397
	<i>Coefficiente R²</i>	0.602513	0.747709	0.593252	0.827997	0.871146	0.602513
T3	<i>Función objetivo</i>	6.218387	2.278674	10.582198	2.540822	0.717179	6.218387
	<i>Valor Máximo del error</i>	0.804800	0.357394	0.905824	0.236019	0.077113	0.804800
	<i>Distribución del error</i>	0.278386	0.102012	0.473746	0.113748	0.032107	0.278386
	<i>Coefficiente R²</i>	0.602490	0.747583	0.593257	0.827996	0.871155	0.602490

En las siguientes secciones se presentan los resultados del modelo de sustitución cuando se aplica el proceso de calibración, tanto en la búsqueda con valores iniciales dados por expertos y como cuando no se tiene la guía de estos. Se muestra inicialmente una descripción cualitativa del proceso de calibración y del ajuste obtenido, para

posteriormente realizar una evaluación cuantitativa de la variación de los criterios. Para finalizar se presentan los resultados de la calibración obtenida cuando no se realiza una búsqueda guiada por expertos y la comparación de estos con el proceso con expertos.

4.2.1 Evaluación cualitativa de los resultados en el modelo de sustitución.

En las figuras de la 4-6 a la 4-10 se muestran, para cada una de las fuentes de energía, el modo de referencia (datos históricos), la simulación inicial (modelo original con estimaciones iniciales de expertos) y las simulaciones del modelo cuando se calibra con cada uno de los métodos. Se observa que existen diferencias entre los datos resultantes por la calibración utilizando cada uno de los métodos optimizados, que se evidencia con la diferencia en la trayectoria en los datos. Estos tienden a seguir la tendencia del ajuste inicial, aunque los datos calibrados tienden a evadir los picos de los datos históricos y guiarse por la tendencia promedio. Las fuentes que visualmente parecen ajustarse mejor a los datos históricos son H y P, mientras que en el caso de Cb se observa una mayor diferencia en las trayectorias.

Figura 4-7: Simulación de la demanda de gas natural del modelo de sustitución.
 Datos de la variable vivienda en todos los periodos de simulación para el caso de los datos históricos, la simulación original y cada uno de las simulaciones optimizadas.




Figura 4-8: Simulación de la demanda de carbón del modelo de sustitución.

Datos de la variable vivienda en todos los periodos de simulación para el caso de los datos históricos, la simulación original y cada uno de las simulaciones optimizadas.




Figura 4-9: Simulación de la demanda de Energías renovables no convencionales del modelo de sustitución.

Datos de la variable vivienda en todos los periodos de simulación para el caso de los datos históricos, la simulación original y cada uno de las simulaciones optimizadas.




Figura 4-10 Simulación de la demanda hidroeléctrica del modelo de sustitución.
 Datos de la variable vivienda en todos los periodos de simulación para el caso de los datos históricos, la simulación original y cada uno de las simulaciones optimizadas.


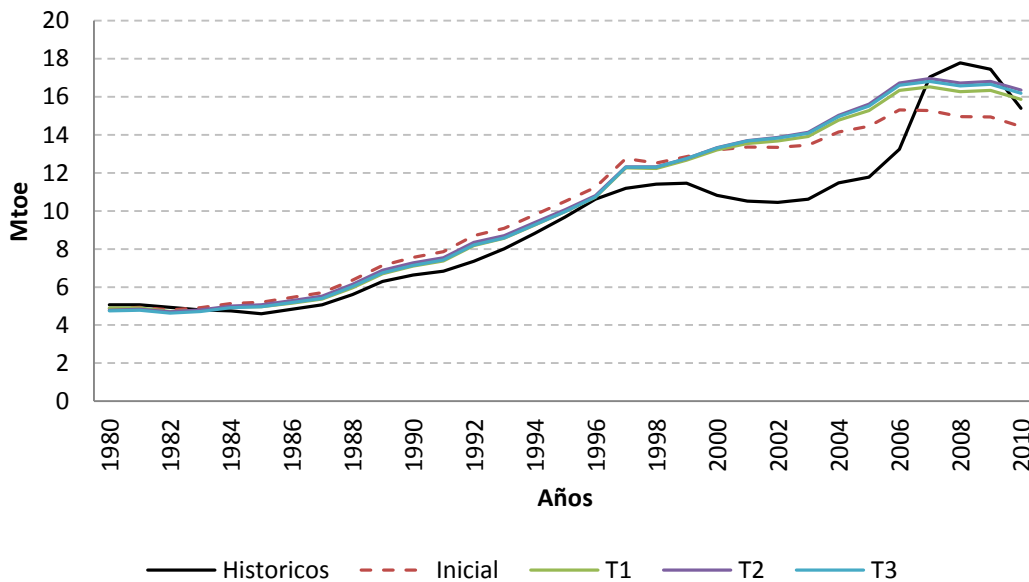


Figura 4-11: Simulación de la demanda de petróleo del modelo de sustitución.
 Datos de la variable vivienda en todos los periodos de simulación para el caso de los datos históricos, la simulación original y cada uno de las simulaciones optimizadas.



Las figuras 4-11, 4-12 y 4-13 muestran el progreso de los métodos durante el proceso de calibración del modelo. En este caso, T1 continúa sin presentar variaciones en el trayecto cuando se cambian la semilla del generador de números aleatorios. T3 presenta una

mayor diversidad de resultados y la convergencia no se da en exactamente el mismo punto, como sucede en el modelo de electrificación. T2 continúa presentando la mayor diversidad de resultados en las corridas, e incluso los resultados de algunas de las corridas se alejan en gran medida del promedio. Tanto para T2 como para T3, fue necesario aumentar el número de muestras a veinte debido a las diferencias en cada corrida del método. De forma similar al modelo de electrificación, los datos obtenidos en las figuras 4-11 y 4-13, relativas a los métodos T1 y T3 se obtuvieron realizando simulaciones parciales, pausando el algoritmo en ciertos puntos de control.

Figura 4-12: Valores de la función objetivo para T1 para el modelo de sustitución.

Datos de la función objetivo durante las iteraciones del proceso de optimización empleando el método T2 para 10 corridas.

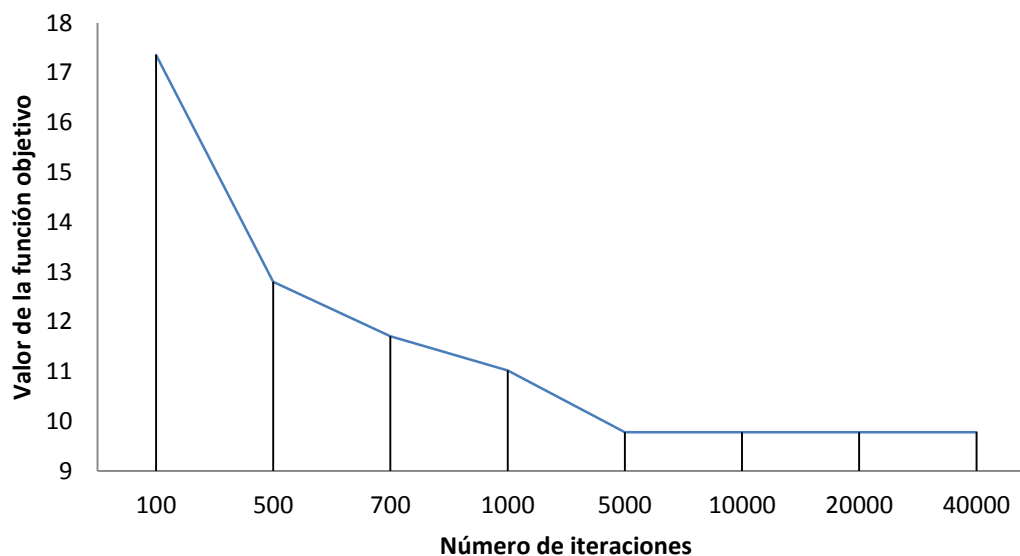


Figura 4-13: Valores de la función objetivo para T2 para el modelo de sustitución.

Datos de la función objetivo durante las iteraciones del proceso de optimización empleando el método T2 para 10 corridas. Cada color representa una corrida diferente.


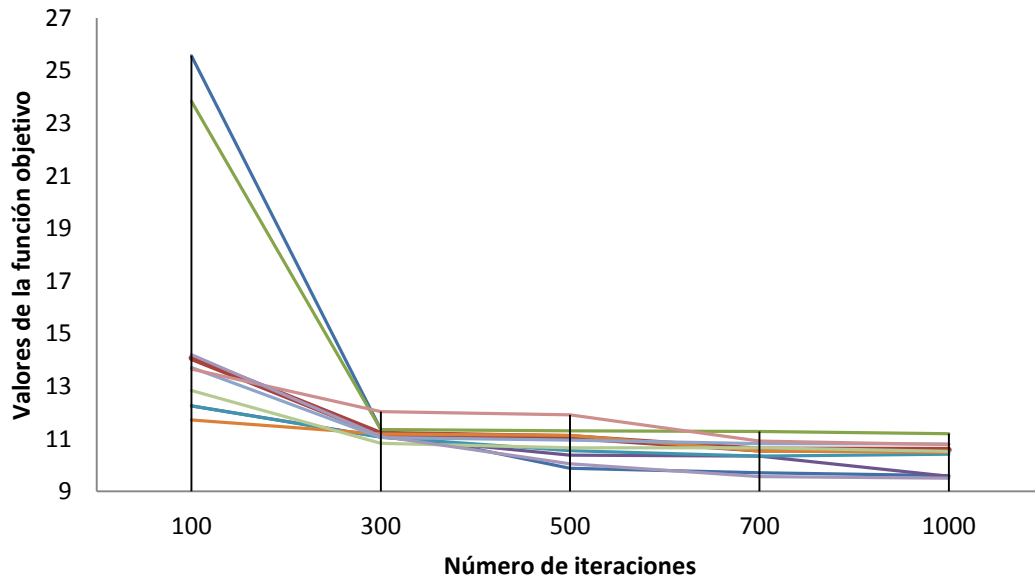


Figura 4-14: Valores de la función objetivo para T3 para el modelo de sustitución.

Datos de la función objetivo durante las iteraciones del proceso de optimización empleando el método T3 para 10 corridas. Cada color representa una corrida diferente.



4.2.2 Evaluación cuantitativa de los resultados en el modelo de sustitución.

(a) Función objetivo

En la tabla 4-18 se presentan los resultados para el criterio de función objetivo de la calibración del modelo empleando cada uno de los métodos. El mejor resultado lo obtiene T1 que logra disminuir en 56.232356% la función objetivo. Este es el método que logra una mayor reducción en las fuentes ERNC, H y P, con mejoras del 66.912838%, 69.871274% y 9.540046% respectivamente. El segundo método con mejor resultado es T3, que reduce la función objetivo en 55.689118%, y obtiene el mejor ajuste en GN aumentando el ajuste un 47.591972%. Por último, se encuentra T2, que se ve dominado por los otros dos métodos en todas la fuentes salvo en Cb; donde obtiene el mejor ajuste con una reducción del 47,136414%.

Tabla 4-18 Valores de la función objetivo del modelo de sustitución calibrado.

Valores de la función objetivo total y de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores

		GN	CB	ERNC	H	P	Suma
T1	Inicial	6.218408	2.277668	10.582950	2.540848	0.717175	22.337050
	Valor	3.291087	1.569434	3.501598	0.765525	0.648757	9.776401
	Variación porcentual	-47.075085%	-31.094712%	-66.912838%	-69.871274%	-9.540046%	-56.232356%
T2	Inicial	6.218322	2.277488	10.582265	2.540831	0.717236	22.336142
	Valor	3.694075	1.203962	4.265996	0.987632	0.777266	10.928932
	Variación porcentual	-40.593699%	-47.136414%	-59.687302%	-61.129566%	8.369623%	-51.070638%
T3	Inicial	6.218387	2.278674	10.582198	2.540822	0.717179	22.337259
	Valor	3.258934	1.249369	3.813174	0.850192	0.726168	9.897837
	Variación porcentual	-47.591972%	-45.171197%	-63.966144%	-66.538720%	1.253382%	-55.689118%

La tabla 4-19 muestra las variaciones en la distribución del error entre las cinco fuentes para cada uno de los métodos de calibración empleados. Las principales fuentes que contribuyen al error siguen siendo el GN y las ERNC, con valores por encima de 0.3. En los tres métodos se reduce la participación de ERNC y H en la función objetivo, y T1 que

obtuvo la mayor reducción en la función objetivo, es el que logra una mejor participación en estas fuentes.

Tabla 4-19. Distribución de la función objetivo en el modelo de sustitución calibrado.

Proporción de la función objetivo que pertenece a cada una de las variables respuesta. Se presentan los valores iniciales y la variación una vez se calibra el modelo. Las flechas indican si incrementa o si disminuye

	T1		T2		T3	
	Valor	Variación	Valor	Variación	Valor	Variación
GN	0.336635	↑0.058246	0.338009	↑0.059611	0.329257	↑0.050870
CB	0.160532	↑0.058564	0.110163	↑0.008198	0.126226	↑0.024214
ERNC	0.358168	↓0.115616	0.390340	↓0.083433	0.385253	↓0.088493
H	0.078303	↓0.035447	0.090369	↓0.023385	0.085896	↓0.027851
P	0.066359	↑0.034252	0.071120	↑0.039009	0.073366	↑0.041259

(b) Valor máximo del error.

En la **tabla 4-20** se encuentran los valores del criterio de error máximo para cada uno de los métodos utilizados. El menor valor lo consigue T1, con un valor máximo equivalente a 0.477751 de la fuente ERNC, aunque es en el GN donde se presenta la mayor reducción, un 58.479775% del valor inicial. Adicionalmente, T1 presenta una reducción en H de 12.653716%, a diferencia de los otros dos métodos que aumentan el error máximo de esta fuente. Además T1 es el método que aumenta en menor proporción el error máximo de P, con un aumento del 24.954710%. T3 se ubica en la segunda posición con un error máximo de 0.509614 del GN, con una reducción del 48.288178% en ERNC, y 42.128265% en Cb, mientras aumenta en 8.464258% el error de H y 37.918547% el error de P. T2 se comporta de forma similar a T3, ya que tiene un error máximo de 0.556763 proveniente del GN, y aunque presenta una mayor reducción en Cb (-50.823133%), tiene un peor desempeño en las demás fuentes.

Tabla 4-20. Valores máximo del error del modelo de sustitución calibrado.

Valores de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores.

		GN	CB	ERNC	H	P
T1	<i>Inicial</i>	0.804897	0.357394	0.906511	0.236019	0.077100
	<i>Valor</i>	0.334195	0.203963	0.477751	0.206154	0.096340
	<i>Variación porcentual</i>	-58.479775%	-42.930549%	-47.297859%	-12.653716%	24.954710%
T2	<i>Inicial</i>	0.804805	0.357394	0.905800	0.236019	0.077113
	<i>Valor</i>	0.556763	0.175755	0.506092	0.294766	0.109285
	<i>Variación porcentual</i>	-30.820105%	-50.823133%	-44.127603%	24.890523%	41.719543%
T3	<i>Inicial</i>	0.804800	0.357394	0.905824	0.236019	0.077113
	<i>Valor</i>	0.509614	0.206830	0.468418	0.255996	0.106353
	<i>Variación porcentual</i>	-36.678267%	-42.128265%	-48.288178%	8.464258%	37.918547%

(c) Coeficiente R²

La tabla 4-21 muestra los valores del coeficiente R² de cada una de las fuentes una vez se emplean los métodos de calibración. Los mayores incrementos se dan sobre ERNC, la fuente con un coeficiente R² inicial más bajo (aproximadamente 0.59). T1 presenta el mayor cambio con una mejora del 22.162894%, seguido de T3 con 15,764382% y T2 con 12,135371%. La mejora en el ajuste hace incluso que la fuente con peor ajuste (una vez calibrado el modelo) sea GN. Adicionalmente, se observa que tanto T1 como T3, presentan una reducción del ajuste en Cb, llevando dicho coeficiente a valores de 0,716576 y 0,746708 respectivamente. Para el caso de H y P, los cuales poseen coeficientes iniciales superiores a 0.8, presentan mejoras alrededor de 4% y 5% con todos los métodos.

Tabla 4-21. Valores del coeficiente R^2 del modelo de sustitución calibrado.

Valores las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores.

		GN	CB	ERNC	H	P
T1	<i>Inicial</i>	0.602509	0.747714	0.593249	0.827997	0.871135
	<i>Valor</i>	0.652965	0.716576	0.724730	0.869139	0.903048
	<i>Variación porcentual</i>	8.374223%	-4.164425%	22.162894%	4.968815%	3.663396%
T2	<i>Inicial</i>	0.602513	0.747709	0.593252	0.827997	0.871146
	<i>Valor</i>	0.603739	0.756410	0.665245	0.859133	0.907513
	<i>Variación porcentual</i>	0.203443%	1.163657%	12.135371%	3.760391%	4.174582%
T3	<i>Inicial</i>	0.602490	0.747583	0.593257	0.827996	0.871155
	<i>Valor</i>	0.649186	0.746708	0.686781	0.869497	0.904689
	<i>Variación porcentual</i>	7.750443%	-0.117021%	15.764382%	5.012157%	3.849389%

(d) Coeficientes de Theil

La variación en los coeficientes de Theil (error de media, varianza y covarianza) para cada una de las fuentes se puede observar en la Tabla 4-22. En general, solo se presentan mejoras en el Cb, ERNC y H, ya que con los tres métodos se producen aumentos en la proporción del error de media en GN y P. En el GN, T3 es el que aumenta en menor medida el error de media, el cual cambia su proporción de 0.094281 a 0.197308, en comparación con 0.210926 de T2 y 0.209150 de T1; este último además, aumenta la proporción del error de varianza a 0.485737. En el caso de Cb, el error se logra transferir al error de covarianza, en el caso de T1 se logra llegar hasta 0.998715, al reducir a su vez el error de varianza. Para ERNC, todos los métodos reducen el error de media y el error de covarianza, pasando el error al error de varianza. H es la fuente que presenta una mayor mejoría, obteniendo una proporción en el error de covarianza superior a 0.9 con todos los métodos de optimización. Por último, el error en P desmejora; si bien la mayoría de la proporción se encuentra en el error de covarianza, esta es menor que la inicial, y contribuye al aumento en el error de media.

Tabla 4-22. Coeficientes de Theil para el modelo de sustitución calibrado.

Proporción del error cuadrático distribuido entre el error de media, el error de varianza y el error de correlación para cada uno de las variables. Se muestra la proporción original, el valor una vez calibrado y una flecha que muestra si aumenta o disminuye.

		Error de Media		Error de Varianza		Error de Covarianza	
		Valor inicial	Valor	Valor inicial	Valor	Valor inicial	Valor
GN	T1	0.094269	↑0.209150	0.451781	↑0.485737	0.453950	↓0.305113
	T2	0.094278	↑0.210926	0.451804	↓0.408485	0.453918	↓0.380588
	T3	0.094281	↑0.197308	0.451800	↓0.430457	0.453920	↓0.372235
Cb	T1	0.150178	↓0.000365	0.015151	↓0.000920	0.834671	↑0.998715
	T2	0.150121	↓0.046458	0.015173	↑0.167066	0.834706	↑0.786476
	T3	0.150159	↓0.076550	0.015159	↑0.139040	0.834683	↑0.784409
ERNC	T1	0.192868	↓0.153066	0.019337	↑0.223661	0.787795	↓0.623273
	T2	0.193055	↓0.188049	0.019263	↑0.169278	0.787682	↓0.642674
	T3	0.193070	↓0.186046	0.019259	↑0.231132	0.787670	↓0.582822
H	T1	0.172236	↓0.011504	0.299470	↓0.012125	0.528294	↑0.976370
	T2	0.172253	↓0.000567	0.299451	↓0.065317	0.528296	↑0.934117
	T3	0.172271	↓0.016941	0.299432	↓0.016333	0.528297	↑0.966727
P	T1	0.238576	↑0.296268	0.004307	↑0.044978	0.757117	↓0.658754
	T2	0.238652	↑0.369631	0.004294	↑0.069426	0.757054	↓0.560942
	T3	0.238645	↑0.324196	0.004299	↑0.071940	0.757056	↓0.603864

En general no se puede definir contundentemente que un método sea superior a otro, debido a que no hay un método que domine a los demás en cada uno de los criterios, pero T1 presenta mejores resultados en la mayoría de los criterios y es el método que logra obtener la mayor reducción en la función objetivo. En segunda posición se podría proponer a T3, y por último T2, que presenta valores inferiores, aunque la diferencia entre los métodos podría ser considerada como leve.

4.2.3 Resultados con búsqueda no guiada en el modelo de electrificación.

(a) Función objetivo

La tabla 4-23 muestra los resultados para el criterio de la función objetivo cuando se aplica el proceso de calibración del modelo sin emplear valores iniciales dados por juicio de expertos. Estos se evalúan con la mejora porcentual respecto a los valores iniciales y se comparan, a su vez, con los resultados arrojados por la calibración guiada por expertos. En este caso, los valores de la función objetivo son mayores a los obtenidos por la búsqueda de expertos. T1 presenta, inclusive, un valor superior al arrojado por el modelo original, desmejorando el ajuste; esto se debe en parte a la falta de ajuste en H y P, ya que el modelo logra mejorar el ajuste en Cb y ERNC. T2 presenta una reducción de la función objetivo en comparación con el resultado inicial, llegando a un valor de 15.738497, aunque este valor es mayor en 4,809565 que el obtenido por la búsqueda guiada por expertos. Complementariamente, T2 es el modelo que presenta una mayor varianza en los resultados arrojados por el proceso de calibración, necesitando un incremento en el número de corridas para obtener una muestra significativa (aplicando el cálculo de número de corridas de Banks con un alfa de 0.05 y un error del 10%). Pese a la diversidad de resultados, en ninguna de las corridas se obtiene un valor de la función objetivo menor al obtenido con búsqueda de expertos; se encuentran muestras con valores aproximados a 11, pero en su mayoría se encuentran alrededor de 19. T3 presenta el menor valor entre los métodos (9,928088), aunque presenta un desajuste en P del 2,484557%. T3 es el método que obtiene valores más cercanos a los arrojados por la búsqueda guiada por expertos.

Tabla 4-23 Valores de la función objetivo del modelo de sustitución calibrado sin guía de expertos.
Valores de la función objetivo total y de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores

		GN	CB	ERNC	H	P	Suma
T1	<i>Inicial</i>	6.218408	2.277668	10.582950	2.540848	0.717175	22.337050
	<i>Valor</i>	6.801603	1.869942	4.671436	39.217864	1.684825	54.245670
	<i>Variación porcentual</i>	9.378526%	-17.901038%	-55.858851%	1443.4950%	134.925%	142.850643%
	<i>Diferencia con Expertos</i>	3.510516	0.300508	1.169838	38.452339	1.036068	44.469269
T2	<i>Inicial</i>	6.218322	2.277488	10.582265	2.540831	0.717236	22.336142
	<i>Valor</i>	5.063667	1.727468	6.202570	1.492919	1.251872	15.738497
	<i>Variación porcentual</i>	-18.568592%	-24.150284%	-41.387119%	-41.242877%	74.541209%	-29.537978%
	<i>Diferencia con expertos</i>	1.369592	0.523506	1.936574	0.505287	0.474606	4.809565
T3	<i>Inicial</i>	6.218387	2.278674	10.582198	2.540822	0.717179	22.337259
	<i>Valor</i>	3.252104	1.284841	3.812271	0.843874	0.734998	9.928088
	<i>Variación porcentual</i>	-47.701810%	-43.614517%	-63.974676%	-66.787353%	2.484557%	-55.553686%
	<i>Diferencia con expertos</i>	-0.006830	0.035472	-0.000903	-0.006318	0.008830	0.030251

La tabla 4-24 muestra la distribución de la función objetivo en cada una de las fuentes. Coherente con los incrementos en la función objetivo, T1 presenta una mayor proporción del error en H, mientras que T2 y T3 concentran la mayoría del error en ERNC y GN, con valores superiores a 0.3, aunque estos no difieren mucho de los valores iniciales o de los obtenidos por la calibración con guía de expertos.

Tabla 4-24. Distribución de la función objetivo en el modelo de sustitución calibrado sin guía de expertos.

Proporción de la función objetivo que pertenece a cada una de las variables respuesta. Se presentan los valores iniciales y la variación una vez se calibra el modelo. Las flechas indican si incrementa o si disminuye.

		GN	CB	ERNC	H	P
T1	Valor	0.125385	0.034472	0.086116	0.722968	0.031059
	Variación	-0.153005	-0.067496	-0.387668	0.609217	-0.001048
	Diferencia con expertos	-0.211251	-0.126061	-0.272052	0.644664	-0.035300
T2	Valor	0.321738	0.109761	0.394102	0.094858	0.079542
	Variación	0.043340	0.007796	-0.079671	-0.018896	0.047431
	Diferencia con expertos	-0.016271	-0.000402	0.003762	0.004489	0.008422
T3	Valor	0.327566	0.129415	0.383988	0.084999	0.074032
	Variación	0.049180	0.027403	-0.089758	-0.028749	0.041925
	Diferencia con expertos	-0.001691	0.003188	-0.001265	-0.000898	0.000666

(b) Valor máximo del error.

Los resultados del modelo optimizado sin guía de expertos para el criterio de error máximo se muestran en la tabla 4-25. En T1 el error máximo incrementa debido a los errores de H y P, que logran máximos de 8,892953 y 0,378167 respectivamente. De forma análoga, los valores de estas fuentes también incrementan en T2 con valores de 0.571420 y 0.250904. En el caso de T3, el error máximo de H y P aumenta, sin embargo los valores obtenidos en este caso son menores que los arrojados por la calibración guiada por expertos en 0.007149 y 0.000454 respectivamente, además de disminuir el error de GN, que es el mayor entre todas la fuentes, a un valor de 0.503732.

Tabla 4-25. Valores máximo del error del modelo de sustitución calibrado sin guía de expertos.

Valores de las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores.

		GN	CB	ERNC	H	P
T1	Inicial	0.804897	0.357394	0.906511	0.236019	0.0771
	Valor	0.642237	0.230951	0.788448	8.892953	0.378167
	Variación porcentual	-20.208779%	-35.379204%	-13.023865%	3667.897155%	390.489522%
	Diferencia con Expertos	0.308042	0.026988	0.310697	8.686799	0.281827
T2	Inicial	0.804805	0.357394	0.9058	0.236019	0.077113
	Valor	0.494007	0.251932	0.521549	0.571420	0.250904
	Variación porcentual	-38.617828%	-29.508672%	-42.421172%	142.107586%	225.372098%
	Diferencia con expertos	-0.062756	0.076177	0.015457	0.276654	0.141619
T3	Inicial	0.804800	0.357394	0.905824	0.236019	0.077113
	Valor	0.503732	0.217818	0.469107	0.248847	0.105899
	Variación porcentual	-37.409020%	-39.053887%	-48.212141%	5.435033%	37.329607%
	Diferencia con expertos	-0.005882	0.010988	0.000689	-0.007149	-0.000454

(c) Coeficiente R^2

Los resultados para el criterio del coeficiente R^2 sin guía de expertos se muestran en la Tabla 4-26. T1 se encuentra dominado en este criterio por los otros dos métodos, presentando una mejoría en el coeficiente R^2 para ERNC en 10.442117%, pero desmejoranda las demás fuentes, inclusive para P que presentaba inicialmente un ajuste cercano a 1. En el caso de T2, si bien se reduce el ajuste de Cb y H, el coeficiente R^2 aumenta para GN en 21,548281%, ERNC en 30,419810% y P en 6,715114%. Estos valores son superiores a los alcanzados con la búsqueda guiada por expertos y a los obtenidos por T3, salvo en el caso de H en el que T3 obtiene un coeficiente R^2 de 0.869278.

Tabla 4-26. Valores del coeficiente R² del modelo de sustitución calibrado sin guía de expertos.

Valores las dos variables respuestas en el caso de la simulación del modelo calibrado por cada uno de los métodos, así como la variación porcentual respecto a los valores iniciales. En verde oscuro se encuentra los mejores valores, y verde claro los segundos mejores.

		GN	CB	ERNC	H	P
T1	Inicial	0.602509	0.747714	0.593249	0.827997	0.871135
	Valor	0.403354	0.587218	0.655197	0.727914	0.242349
	Variación porcentual	-33.054356%	-21.464952%	10.442117%	-12.087315%	-72.180089%
	Diferencia con Expertos	-0.249611	-0.129358	-0.069533	-0.141225	-0.660699
T2	Inicial	0.602513	0.747709	0.593252	0.827997	0.871146
	Valor	0.732344	0.603650	0.773718	0.756534	0.929644
	Variación porcentual	21.548281%	-19.266673%	30.419810%	-8.630802%	6.715114%
	Diferencia con expertos	0.128605	-0.152760	0.108473	-0.102599	0.022131
T3	Inicial	0.602490	0.747583	0.593257	0.827996	0.871155
	Valor	0.650350	0.741386	0.686633	0.869278	0.903664
	Variación porcentual	7.943619%	-0.828903%	15.739529%	4.985786%	3.731658%
	Diferencia con expertos	0.001164	-0.005322	-0.000148	-0.000219	-0.001025

(a) Coeficientes de Theil

En la tabla 4-27, se encuentra la distribución del error de Theil para el modelo calibrado sin guía de expertos. Para GN, los tres métodos presentan desmejoras al aumentar el error de media y reducir el error de covarianza, incluso T3 disminuye el error de varianza. Cb, presenta mejorías cuando se emplean T1 o T2, pero T3 compensa la disminución del error de media con una disminución en el error de covarianza, como hace de igual forma para ERNC. En ERNC, T1 disminuye tanto el error de media como el error de varianza, para enfocar la mayoría del error en la covarianza; caso contrario a T2. Para H, se transfiere en su mayoría los errores al error covarianza, alcanzando valores cercanos a 1 para T2 y T3. T1 por su parte lleva el error de covarianza al error de media y el error de

varianza. Por último, P presenta aumentos en el error de media en el caso de T2 y T3. Y si bien, este aumento es similar para ambos métodos (0,33 aproximadamente), el aumento en el error de media de T2 proviene de la reducción del error de covarianza, mientras que para T3 se aumenta al reducir el error de varianza.

Tabla 4-27 Coeficientes de Theil para el modelo de sustitución calibrado sin guía de expertos.

Proporción del error cuadrático distribuido entre el error de media, el error de varianza y el error de correlación para cada uno de las variables. Se muestra la proporción original, el valor una vez calibrado y una flecha que muestra si aumenta o disminuye.

		Error de Media		Error de Varianza		Error de Covarianza	
		Valor inicial	Valor	Valor inicial	Valor	Valor inicial	Valor
GN	T1	0.094269	↑0.345877	0.451781	↑0.562920	0.453950	↓0.091203
	T2	0.094278	↑0.298733	0.451804	↑0.627394	0.453918	↓0.073874
	T3	0.094281	↑0.198482	0.451800	↓0.431108	0.453920	↓0.370410
Cb	T1	0.150178	↓0.009285	0.015151	↑0.098109	0.834671	↑0.892605
	T2	0.150121	↓0.045614	0.015173	↑0.163941	0.834706	↑0.790445
	T3	0.150159	↓0.068065	0.015159	↑0.120269	0.834683	↓0.811666
ERNC	T1	0.192868	↓0.084405	0.019337	↓0.010515	0.787795	↑0.905080
	T2	0.193055	↑0.338643	0.019263	↑0.541948	0.787682	↓0.119409
	T3	0.193070	↓0.187902	0.019259	↑0.236038	0.787670	↓0.576059
H	T1	0.172236	↑0.305737	0.299470	↑0.623032	0.528294	↓0.071231
	T2	0.172253	↓0.024012	0.299451	↓0.010597	0.528296	↑0.965392
	T3	0.172271	↓0.011020	0.299432	↓0.018830	0.528297	↑0.970150
P	T1	0.238576	↓0.166305	0.004307	↑0.203461	0.757117	↓0.630235
	T2	0.238652	↑0.335431	0.004294	↑0.412531	0.757054	↓0.252038
	T3	0.238645	↑0.328498	0.004299	↑0.065752	0.757056	↓0.605750

En general se observa que en un modelo como el modelo de sustitución presentado en esta sección, el cual cuenta con un gran variedad de parámetros a calibrar, una mayor cantidad de variables, relaciones y en general una dinámica compleja es importante realizar una estimación inicial de los parámetros a calibrar ya que afecta notoriamente los resultados arrojados por los métodos de optimización. Presentándose el caso, inclusive, en el que se obtiene un mejor resultado teniendo una estimación inicial de los parámetros que empleando el proceso de calibración, como se muestra para el caso de T1.

5. Conclusiones y recomendaciones

El proceso de calibración es un proceso complementario en Dinámica de sistemas que permite mejorar la representatividad de los modelos y aumentar la confianza en ellos, mediante el uso de algoritmos de optimización en la estimación de los valores de parámetros sobre los que se tiene incertidumbre o no es posible conocer su valor exacto por observación directa (Vanni et al., 2011). Para este proceso se recomienda emplear métodos de optimización metaheurística, ya que no es posible en la mayoría de los casos encontrar una solución analítica y optimizadores lineales pueden encontrar dificultades dada la complejidad y alta no linealidad de los sistemas estudiados.

Existen diferentes metaheurísticas, pero dada la característica de proceso complementario de la calibración, se emplea usualmente el algoritmo incluido en el programa de simulación empleado para el modelamiento. Sin embargo, los programas se limitan a implementar solo un algoritmo y esto evita un seguimiento y una verificación de los resultados de la calibración. Por lo que el modelador debe invertir tiempo y esfuerzo en traducir su modelo a diferentes lenguajes de programación si desea corroborar que el ajuste obtenido en el proceso es bueno. De igual forma, tampoco se encuentra en la literatura revisada una comparación o un análisis sobre las diferencias de la selección del método de optimización en el ajuste logrado por la calibración del modelo específicamente para el caso de modelos de Dinámica de sistemas, que le permita asegurar al modelador que los resultados obtenidos son buenos.

Se seleccionaron dos modelos: el modelo de electrificación presentado como tutorial en el programa Vensim (VENTANA Systems inc, 2010) y el modelo de sustitución de fuentes energéticas de Moxnes (Moxnes, 1990) aplicado en el caso de Chile por Rua (2014), que se diferencian en nivel de complejidad dinámica (dada la cantidad de variables, niveles y ciclos) y en los cuales se observó una posibilidad de emplear la calibración para mejorar el ajuste del modelo. Sobre estos modelos se probaron tres

diferentes metaheurísticas: el optimizador asociado a Powersim Studio 10 (T3) el cual emplea como base algoritmos genéticos, uno de los métodos más estudiados y con mayores variaciones en la literatura; el optimizador asociado a Vensim (T1) que se basa en el algoritmo de Powell, un algoritmo que emplea una optimización lineal de cada una de las variables y que es comúnmente empleado por su diseño intuitivo que ha servido de base a muchos otros algoritmos; y un tercer algoritmo denominado OPTQUEST, un algoritmo reciente que se ha empezado a emplear en múltiples programas de simulación y es el resultado de la combinación de estrategias de búsqueda de diferentes metaheurísticas (tabú, programación entera, redes neuronales y búsqueda dispersa).

Para la evaluación del desempeño de los métodos se propuso un análisis offline, debido a que el enfoque de la investigación se centra en el ajuste del modelo y del resultado final del proceso de calibración como un conjunto, más que en las características propias del diseño del algoritmo. Además, se optó por este tipo de evaluación debido a que existen dificultades en el seguimiento del proceso interno de los algoritmos, dado la confidencialidad que manejan los programas y los outputs del proceso que muestran estos, esta falencia se solventó en cierta medida interrumpiendo el proceso en algunos puntos de control para observar de forma aproximada el recorrido de los algoritmos. Por tal motivo se propusieron como criterios: la reducción de la función objetivo, medida como el error cuadrático porcentual de la diferencia entre los datos simulados y los datos históricos, que permite una comparación de los errores en una función multiobjetivo eliminando el peso de la diferencia de dimensiones de las variables; la reducción del error máximo, que permite definir límites en relación al error alcanzado en los periodos de simulación; y el coeficiente R^2 que mide el nivel en que el modelo representa el sistema real. Adicionalmente se emplearon los coeficientes de Theil y la distribución del error para analizar la preferencia de los algoritmos por las variables a optimizar y las fuentes del error.

En el caso de T1 (algoritmo asociado a Vensim) se observó durante la realización del estudio que no presenta variaciones significativas respecto diferentes corridas o cambio en la raíz generadora de números aleatorios y en general se obtiene una convergencia dentro de las primeras 500 iteraciones, que permanece hasta la próxima condición de parada (tiempo o máximo de iteraciones). Esto genera desconfianza en relación al

desempeño de exploración del algoritmo, pero puede deberse a la programación propia del programa que suele aproximar los valores obtenidos durante la simulación, omitiendo diferencias con el nivel de significancia trabajado (0,000001). Como resultado en el modelo de electrificación, el algoritmo logra obtener una reducción del error cuadrático porcentual del 97.426016%, con diferencias con los datos históricos inferiores a 0.130307, y aumento en el coeficiente R^2 hasta valores superiores a 0.985, transfiriendo el error de media a los errores de varianza y covarianza. Cuando se emplea una búsqueda sin guía de expertos (sin un indicio de los valores iniciales de los parámetros), el algoritmo en el modelo de electrificación alcanza valores similares a los obtenidos por la búsqueda con expertos, se obtiene un mayor valor en la función objetivo, pero se incrementa el coeficiente R^2 . Para el caso del modelo de sustitución de fuentes de energía, el método presenta una reducción en la función objetivo de 56.232356%, centrando principalmente el error en el Gas Natural (GN) y las energías renovables (ERNC), adicionalmente se reducen los valores máximos del error, salvo en el caso del petróleo (P), obteniendo un error máximo en la simulación del 24.954710%; también se obtiene una mejoría en los coeficientes R^2 de cada una de las fuentes a excepción del carbón (CB) que disminuye en 4.164425%. A diferencia del modelo de electrificación, cuando se emplea este algoritmo en el modelo de sustitución sin valores iniciales asignados por expertos, los resultados obtenidos son peores que los valores iniciales (valores del modelo con una estimación inicial de expertos).

Cuando se emplea T2 (algoritmo asociado a OPTQUEST), se obtiene una mayor diversidad de soluciones y la convergencia no se da sobre siempre sobre valores cercanos, lo exige un mayor tiempo de simulación y un mayor número de corridas del método para obtener la mejor solución, lo que hace que el método tenga un promedio superior. Con este método se logra obtener en el modelo de electrificación una reducción del error cuadrático porcentual del 97.452895%, con valores máximo del error en la simulación de 0.135611 y coeficientes R^2 de las variables superiores a 0,988. Cuando se emplea una calibración de este mismo modelo, sin una guía de expertos (sin tener en cuenta la estimación inicial de los parámetros) se obtienen variaciones del orden de 0.00001 en la función objetivo, en comparación con el ajuste inicial con estimaciones iniciales de los parámetros por expertos, sin embargo se mejora el coeficiente R^2 . En el modelo de sustitución, el método obtiene una reducción en la función objetivo total de 51.070638%, que se debe a la reducción del error en todas las fuentes salvo en P que

aumenta en un 8.369623%; aunque el error se centra principalmente en GN y ERNC que obtienen un porcentaje del error total superior al 30%. También se aumenta el error máximo en los periodos de simulación para P y H, y se presenta un aumento en el coeficiente R^2 de todas las fuentes. (Diferencia con búsqueda desde ceros)

En el caso de la calibración empleando T3 (algoritmo asociado a Powersim Studio), se encuentra una variedad de resultados dada la aleatorización del algoritmo, pero en todas las corridas el algoritmo tiende a converger al mismo valor luego de 300 iteraciones. En el modelo de electrificación, presenta una reducción del error cuadrático porcentual de 97.452830%, errores máximos en tiempo de simulación de 0.135602, con un aumento en el coeficiente R^2 superior a 0.988; trasladando el error de media a los errores de varianza y covarianza. Este método no presenta variaciones significativas en la función objetivo y el error máximo cuando se realiza una búsqueda sin guía de expertos, aunque si mejora el coeficiente R^2 . En el modelo de sustitución, el método logra una reducción en la función objetivo total de 55.689118% aunque presenta un aumento en el error de P de 1,253382%. De forma similar a T2, el error se enfoca en GN y ERNC, disminuyendo los valores máximos del error en P y H; y disminuyendo el coeficiente R^2 del Cb en 0,117021%. Para ambos modelos, el método T2 no presenta variaciones significativas cuando se realiza una búsqueda no guiada por valores de expertos, en relación a los criterios de la función objetivo y el error máximo, sin embargo presenta aumentos con este método en el coeficiente R^2 .

De forma comparativa, no se puede definir que un método es mejor que los otros dado que los tres métodos presentan mejoras en el ajuste de los modelos según los criterios de evaluación seleccionados, y no existe un algoritmo que domine a los demás en cada uno de los modelos. Para el modelo de electrificación, los resultados arrojados por los tres métodos de optimización son cercanos a los puntos óptimos de cada uno de los criterios de evaluación, verificando de esta forma la facilidad y la precisión que logran los métodos en un modelo con una dinámica simple como la de este modelo. Si bien la diferencia entre métodos es significativa, la diferencia puede ser asumida por el modelador y seleccionar como bueno cualquiera de los ajustes obtenidos por los métodos de optimización. Aunque T3 obtiene una mejor posicionamiento a lo largo de los

diferentes criterios, lo que unido a la variabilidad y convergencia del proceso, se podría decir que es preferible en este modelo.

En el modelo de sustitución, las diferencias entre los resultados son más notorias. Se verifica que dada la complejidad de la dinámica del sistema y la existencia de múltiples puntos óptimos, existen diferencias entre las preferencias de los métodos de optimización por obtener un ajuste general del sistema. En este caso es más complejo definir un mejor método porque adicional a los múltiples criterios se debe tener en cuenta el ajuste en cada una de las fuentes de energía. Los valores de los criterios son menores en comparación a los obtenidos en el modelo de electrificación, y más alejados de los puntos óptimos de cada criterio, presentándose incluso desajuste en algunas de las fuentes (tomando como base la simulación original). Este efecto se observa en los valores alcanzados por cada uno de los métodos, algunos obtienen mejoras en fuentes específicas como el Cb en el caso de T2, mientras que T3 por su parte sacrifica ajuste en P para alcanzar un ajuste mayor en el sistema general. También se verifica que el modelo de sustitución, dada su complejidad, número de variables, interacciones, presenta una mayor sensibilidad a la búsqueda de parámetros óptimos cuando se tiene la guía de expertos, los resultados arrojados por los métodos cuando no se tiene una guía de experto son peores que los obtenidos cuando se fijan valores estimativos iniciales de los parámetros, además de presentar una mayor variabilidad en los resultados de cada una de las corridas del método.

5.1 Cumplimiento de los objetivos

- *Identificar los elementos característicos principales del proceso de calibración en modelos de DS.* Se definieron como elementos principales la función objetivo, la selección de parámetros y los métodos de optimización, y se tuvieron en cuenta las consideraciones de autores como Keloharju y Dangerfield para las consideraciones metodológicas de emplear un proceso de calibración.
- *Seleccionar, analizar y diferenciar varios métodos usados, o con potencial de uso, en la calibración de modelos de dinámica de sistemas.* Posterior a la identificación de los elementos, se seleccionó el error cuadrático porcentual como función objetivo; y algoritmos genéticos, el algoritmo de Powell y Optquest como

metaheurísticas a estudiar, dado el interés de la investigación y las ventajas que proporcionan cada uno de ellos.

- *Proponer métricas que permitan evaluar el desempeño de diferentes métodos de optimización en la calibración de dos modelos de DS establecidos.* Se propuso un análisis *offline* (de los resultados finales del algoritmo, más que de su proceso para obtener una solución) de los modelos empleado los criterios de error cuadrático porcentual, el error máximo y el coeficiente R^2 , ya que estos permiten observar el ajuste final obtenido por los métodos de optimización. Y se complementaron evaluaciones cualitativas.
- *Evaluar, según los criterios planteados, el desempeño de cada uno de los métodos de optimización en el proceso de calibración para los modelos seleccionados.* Se llevó a cabo el experimento, empleando dos diferentes modelos de DS y se presentaron los resultados de cada uno de ellos, realizando un análisis comparativo posterior.

5.2 Recomendaciones y trabajo futuro

- No pensar en la calibración como un proceso secundario o completamente aislado. Es importante que se realice un estudio minucioso del modelo y se analicen de forma minuciosa los elementos del proceso de calibración, antes de llevarse a cabo. Una selección apropiada de parámetros, función objetivo y método de optimización puede llevar a que se obtengan mejores resultados en el ajuste del modelo.
- En modelos como el de electrificación presentado en este trabajo, en los que se obtiene de forma rápida valores cercanos a los óptimos de los criterios, se sugiere realizar diferentes corridas del algoritmo empleado para verificar los resultados obtenidos por el proceso de calibración. Sin embargo, en modelos más complejos donde es posible encontrar múltiples óptimos locales y en los cuales se tienen diferentes variables respuestas, se sugiere realizar la verificación de los resultados empleando un algoritmo diferente, además de las múltiples corridas. Sería útil si los programas de simulación incluyeran en sus programación

diferentes tipos de algoritmos y de esta forma no sería necesario traducir el modelo a otros lenguajes de programación.

- Es necesario ampliar el banco de casos en los que se aplican apliquen los diferentes métodos, así como el de los métodos estudiados. En orden de generalizar los resultados, se podrían emplear modelos básicos o arquetipos para analizar el efecto en diferentes dinámicas.

A. Anexo: Ecuaciones del modelo de electrificación

A continuación presenta las principales ecuaciones del modelo de electrificación.

$$Non_electric_contacts(i) = Non_electric_households(i) * Contact_rate$$

$$Fraction_electric(i) = Electric_Households(i)/Total_US_Household(i)$$

$$Electric_to_non_electric_contacts(i) = Fraction_electric(i) * Non_electric_contacts(i);$$

$$Net_Household_additions(i) = Total_US_Household(i) * Household_addition_rate;$$

$$Percent_of_US_dwelling_with_electric_power(i) = Fraction_electric(i) * 100;$$

$$conversion(i) = Electric_to_non_electric_contacts(i) * Conversion_Fraction;$$

$$US_population(i) = Total_US_Household(i) * Average_household_size;$$

$$\begin{aligned} Non_electric_households(i+1) \\ &= Non_electric_households(i) - conversion(i) + (1 - Fraction_electric(i)) \\ &\quad * Net_Household_additions(i); \end{aligned}$$

$$\begin{aligned} Electric_Households(i + 1) \\ &= Electric_Households(i) + conversion(i) + Fraction_electric(i) \\ &\quad * Net_Household_additions(i); \end{aligned}$$

$$Total_US_Household(i + 1) = Total_US_Household(i) + Net_Household_additions(i);$$

$$Historicos_Population(i);$$

$$Historicos_Dwellings(i);$$

$$\begin{aligned} Error_Population(i) \\ &= ((Historicos_Population(i) \\ &\quad - US_population(i))/(Historicos_Population(i)))^2; \end{aligned}$$

$$\begin{aligned} \text{Error_Dwellings}(i) &= ((\text{Historicos_Dwellings}(i) \\ &\quad - \text{Percent_of_US_dwellinds_whit_electric_power}(i)) \\ &\quad / (\text{Historicos_Dwellings}(i)))^2; \end{aligned}$$

$$\text{Error_Population_acumulado}(i + 1) = \text{Error_Population_acumulado}(i) + \text{Error_Population}(i);$$

$$\text{Error_Dwellings_acumulado}(i + 1) = \text{Error_Dwellings_acumulado}(i) + \text{Error_Dwellings}(i);$$

$$\begin{aligned} \text{Error_total}(i) &= (0.25 * \text{Error_Dwellings_acumulado}(i)) + (3/10000000) \\ &\quad * \text{Error_Population_acumulado}(i); \end{aligned}$$

B. Anexo: Ecuaciones del modelo de sustitución.

A continuación presenta las principales ecuaciones del modelo de sustitución:

$$\begin{aligned} \text{Costo_GN}(i) &= (\text{Ccap_GN} / \text{TRI_GN}) + \text{Cop_GN} + ((\text{Precio_GN}(i) + \text{Pco2_GN} \\ &\quad * \text{Qco2_GN}) / \text{E_GN}) - \text{Premium_GN}; \\ \text{EN_GN}(i) &= 2.71828182845904^{(-\text{alfa} * \text{Costo_GN}(i))}; \\ \text{Transf_Eq_GN}(i) &= \text{CI_EN_GN}(i) / (\text{Tvida_Eq_GN} / 2); \\ \text{Desecho_Eq_GN}(i) &= \text{CI_EV_GN}(i) / (\text{Tvida_Eq_GN} / 2); \\ \text{CI_GN}(i) &= \text{CI_EN_GN}(i) + \text{CI_EV_GN}(i); \end{aligned}$$

$$\begin{aligned} \text{Costo_Cb}(i) &= (\text{Ccap_Cb} / \text{TRI_Cb}) + \text{Cop_Cb} + ((\text{Precio_Cb}(i) + \text{Pco2_Cb} * \text{Qco2_Cb}) / \text{E_Cb}) \\ &\quad - \text{Premium_Cb}; \\ \text{EN_Cb}(i) &= 2.71828182845904^{(-\text{alfa} * \text{Costo_Cb}(i))}; \\ \text{Transf_Eq_Cb}(i) &= \text{CI_EN_Cb}(i) / (\text{Tvida_Eq_Cb} / 2); \\ \text{Desecho_Eq_Cb}(i) &= \text{CI_EV_Cb}(i) / (\text{Tvida_Eq_Cb} / 2); \\ \text{CI_Cb}(i) &= \text{CI_EN_Cb}(i) + \text{CI_EV_Cb}(i); \end{aligned}$$

$$\begin{aligned} \text{Costo_H}(i) &= (\text{Ccap_H} / \text{TRI_H}) + \text{Cop_H} + ((\text{Precio_H} + \text{Pco2_H} * \text{Qco2_H}) / \text{E_H}) \\ &\quad - \text{Premium_H}; \\ \text{EN_H}(i) &= 2.71828182845904^{(-\text{alfa} * \text{Costo_H}(i))}; \\ \text{Transf_Eq_H}(i) &= \text{CI_EN_H}(i) / (\text{Tvida_Eq_H} / 2); \\ \text{Desecho_Eq_H}(i) &= \text{CI_EV_H}(i) / (\text{Tvida_Eq_H} / 2); \\ \text{CI_H}(i) &= \text{CI_EN_H}(i) + \text{CI_EV_H}(i); \end{aligned}$$

$$\begin{aligned} \text{Costo_ERNC}(i) &= (\text{Ccap_ERNC} / \text{TRI_ERNC}) + \text{Cop_ERNC} + ((\text{Precio_ERNC} + \text{Pco2_ERNC} \\ &\quad * \text{Qco2_ERNC}) / \text{E_ERNC}) - \text{Premium_ERNC}; \\ \text{EN_ERNC}(i) &= 2.71828182845904^{(-\text{alfa} * \text{Costo_ERNC}(i))}; \\ \text{Transf_Eq_ERNC}(i) &= \text{CI_EN_ERNC}(i) / (\text{Tvida_Eq_ERNC} / 2); \\ \text{Desecho_Eq_ERNC}(i) &= \text{CI_EV_ERNC}(i) / (\text{Tvida_Eq_ERNC} / 2); \\ \text{CI_ERNC}(i) &= \text{CI_EN_ERNC}(i) + \text{CI_EV_ERNC}(i); \end{aligned}$$

$$\begin{aligned} \text{Costo_P}(i) &= (\text{Ccap_P} / \text{TRI_P}) + \text{Cop_P} + ((\text{Precio_P}(i) + \text{Pco2_P} * \text{Qco2_P}) / \text{E_P}) \\ &\quad - \text{Premium_P}; \\ \text{EN_P}(i) &= 2.71828182845904^{(-\text{alfa} * \text{Costo_P}(i))}; \\ \text{Transf_Eq_P}(i) &= \text{CI_EN_P}(i) / (\text{Tvida_Eq_P} / 2); \\ \text{Desecho_Eq_P}(i) &= \text{CI_EV_P}(i) / (\text{Tvida_Eq_P} / 2); \\ \text{CI_P}(i) &= \text{CI_EN_P}(i) + \text{CI_EV_P}(i); \end{aligned}$$

$$\text{CI_total}(i) = \text{CI_GN}(i) + \text{CI_H}(i) + \text{CI_Cb}(i) + \text{CI_P}(i) + \text{CI_ERNC}(i);$$

```

Demanda_Total(i)
    = Demanda_GN(i) + Demanda_H(i) + Demanda_Cb(i) + Demanda_P(i)
    + Demanda_ERNC(i);

DO_(i) = Desecho_Eq_GN(i) + Desecho_Eq_H(i) + Desecho_Eq_Cb(i) + Desecho_Eq_P(i)
    + Desecho_Eq_ERNC(i);
X(i) = (Demanda_Total(i) - CI_total(i)) / (DO_(i));

if X(i) >= 0 then FX(i) = X(i) + 1 else FX(i) = 2.71^((0.231 * X(i)));

inversion(i) = DO_(i) * FX(i);
total_EN(i) = EN_GN(i) + EN_H(i) + EN_Cb(i) + EN_P(i) + EN_ERNC(i);

Demanda_SIC_GN(i) = Demanda_Total(i) * (CI_GN(i) / CI_total(i));
Error_GN(i) = (((Demanda_GN(i) - Demanda_SIC_GN(i)) / Demanda_GN(i)) ^ 2);
Prop_EN_GN(i) = EN_GN(i) / total_EN(i);
Inv_GN(i) = inversion(i) * Prop_EN_GN(i);

Demanda_SIC_Cb(i) = Demanda_Total(i) * (CI_Cb(i) / CI_total(i));
Error_Cb(i) = (((Demanda_Cb(i) - Demanda_SIC_Cb(i)) / Demanda_Cb(i)) ^ 2);
Prop_EN_Cb(i) = EN_Cb(i) / total_EN(i);
Inv_Cb(i) = inversion(i) * Prop_EN_Cb(i);

Demanda_SIC_H(i) = Demanda_Total(i) * (CI_H(i) / CI_total(i));
Error_H(i) = (((Demanda_H(i) - Demanda_SIC_H(i)) / Demanda_H(i)) ^ 2);
Prop_EN_H(i) = EN_H(i) / total_EN(i);
Inv_H(i) = inversion(i) * Prop_EN_H(i);

Demanda_SIC_ERNC(i) = Demanda_Total(i) * (CI_ERNC(i) / CI_total(i));

if Demanda_ERNC(i) ≤ 0.0 then Error_ERNC(i) = Demanda_SIC_ERNC(i) else Error_ERNC(i)
    = (((Demanda_ERNC(i) - Demanda_SIC_ERNC(i)) / Demanda_ERNC(i)) ^ 2);

Prop_EN_ERNC(i) = EN_ERNC(i) / total_EN(i);
Inv_ERNC(i) = inversion(i) * Prop_EN_ERNC(i);

Demanda_SIC_P(i) = Demanda_Total(i) * (CI_P(i) / CI_total(i));
Error_P(i) = (((Demanda_P(i) - Demanda_SIC_P(i)) / Demanda_P(i)) ^ 2);
Prop_EN_P(i) = EN_P(i) / total_EN(i);
Inv_P(i) = inversion(i) * Prop_EN_P(i);

Error_Total(i) = (Error_GN(i) + Error_H(i) + Error_Cb(i) + Error_P(i) + Error_ERNC(i));
Error_Acum(i + 1) = Error_Acum(i) + (Error_Total(i));

CI_EN_GN(i + 1) = CI_EN_GN(i) + Inv_GN(i) - Transf_Eq_GN(i);
CI_EV_GN(i + 1) = CI_EV_GN(i) + Transf_Eq_GN(i) - Desecho_Eq_GN(i);

CI_EN_Cb(i + 1) = CI_EN_Cb(i) + Inv_Cb(i) - Transf_Eq_Cb(i);
CI_EV_Cb(i + 1) = CI_EV_Cb(i) + Transf_Eq_Cb(i) - Desecho_Eq_Cb(i);

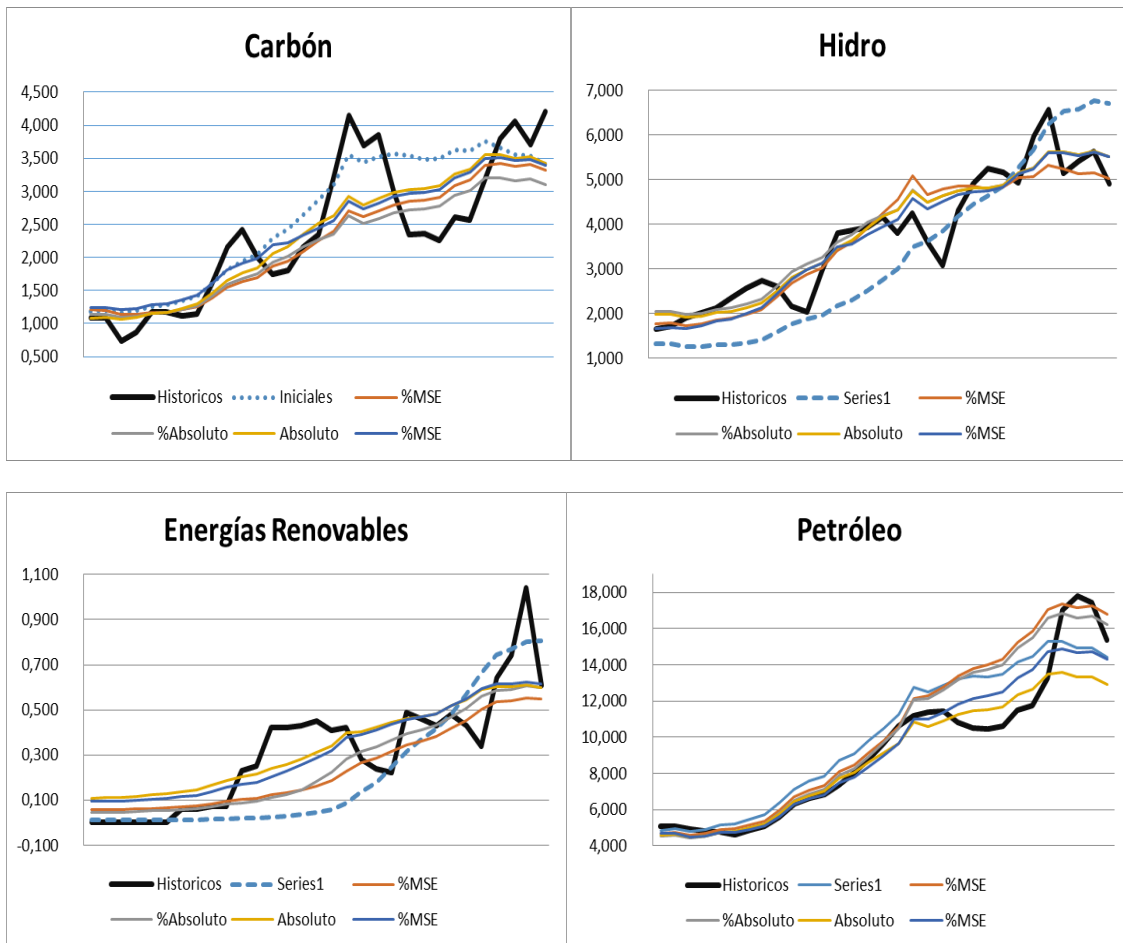
CI_EN_ERNC(i + 1) = CI_EN_ERNC(i) + Inv_ERNC(i) - Transf_Eq_ERNC(i);
CI_EV_ERNC(i + 1) = CI_EV_ERNC(i) + Transf_Eq_ERNC(i) - Desecho_Eq_ERNC(i);


```

$$\begin{aligned} CI_{EN_H}(i+1) &= CI_{EN_H}(i) + Inv_H(i) - Transf_{Eq_H}(i); \\ CI_{EV_H}(i+1) &= CI_{EV_H}(i) + Transf_{Eq_H}(i) - Desecho_{Eq_H}(i); \end{aligned}$$

$$\begin{aligned} CI_{EN_P}(i+1) &= CI_{EN_P}(i) + Inv_P(i) - Transf_{Eq_P}(i); \\ CI_{EV_P}(i+1) &= CI_{EV_P}(i) + Transf_{Eq_P}(i) - Desecho_{Eq_P}(i); \end{aligned}$$

C. Anexo: Revisión preliminar de la selección de función objetivo





Comparación de los datos históricos y los datos simulados de cada fuente luego de aplicar la optimización con cada función objetivo. (Continuación)

El error porcentual cuadrático es la función que se logra minimizar en una mayor medida aplicando la optimización, siendo precedida por el error cuadrático simple; pero a diferencia de las demás funciones, el error cuadrático porcentual es la única función que desmejora el ajuste en algunas de sus fuentes, como se observa en la tabla 1.

Tabla 1: Mejora porcentual del valor de la función objetivo respecto al valor inicial de cada una de las fuentes.

	<i>%MSE</i>	<i>%Absoluto</i>	<i>Absoluto</i>	<i>MSE</i>
<i>Carbón</i>	38,6%	23,1%	11,3%	14,7%
<i>Hidro</i>	59,7%	50,6%	52,0%	71,1%
<i>ERNC</i>	57,3%	39,9%	22,6%	52,6%
<i>GN</i>	44,5%	35,4%	18,4%	31,8%
<i>Petróleo</i>	-11,8%	24,3%	36,6%	45,5%
<i>Total</i>	49,9%	36,5%	30,9%	41,4%

También existe una diferencia respecto a la varianza de los errores, pero en este caso no sólo el error cuadrático presenta reducciones para el caso del petróleo, sino que también lo hacen el error absoluto y el error absoluto porcentual. El error absoluto, presenta de igual forma un aumento en la varianza del GN, y continúa siendo dominado por el MSE.

En la tabla 4 se puede observar qué un cambio en la distribución del error una vez se realiza la optimización, nos puede dar un indicio de las preferencias de estimación del algoritmo a la hora de optimizar. Con los errores porcentuales se le restan porcentaje a la Hidro y las ERNC para aumentarle participación a las demás fuentes. Por su parte, los

errores simples además de reducirle participación a las Hidro y las ERNC., reducen la participación del P.

Tabla 3: Mejora porcentual de la varianza respecto a su valor inicial de cada una de las fuentes.

Fuente	%MSE	%Absoluto	Absoluto	MSE
<i>Cb</i>	60,5%	46,9%	12,7%	28,8%
<i>Hidro</i>	26,0%	15,2%	48,0%	77,7%
<i>ERNC</i>	82,4%	52,2%	64,7%	66,9%
<i>GN</i>	41,0%	6,3%	-1,0%	54,5%
<i>P</i>	-275,2%	-129,2%	-54,7%	39,1%

Tabla 4: Variación en la distribución del error en cada una de las fuentes.

Fuente	%MSE	%Absoluto	Absoluto	MSE
<i>Cb</i>	2,3%	3,2%	3,3%	2,2%
<i>Hidro</i>	-2,2%	-3,8%	-6,4%	-6,6%
<i>ERNC</i>	-7,0%	-1,7%	0,4%	-0,1%
<i>GN</i>	3,0%	0,5%	5,4%	7,1%
<i>P</i>	4,0%	1,8%	-2,8%	-2,6%

Por último, es importante observar cómo afecta la calibración a la dinámica propia del modelo. Para ello se estudia la correlación con los datos históricos. La tabla 5, muestra como con todas las funciones objetivo, salvo el error cuadrático porcentual (en las fuentes *Cb* e *Hidro*), mejoran la correlación entre los datos simulados y los históricos. Para este caso, y a diferencia de criterios anteriores, el valor absoluto no se ve superado por el MSE, presentando valores mayores en relación a la correlación de *ERNC* y *Cb*.

Tabla 5: Variación del coeficiente de correlación respecto a su valor inicial en cada una de las fuentes.

Fuente	%MSE	%Absoluto	Absoluto	MSE
<i>Cb</i>	-0,1%	0,3%	0,4%	0,3%
<i>Hidro</i>	-0,5%	2,0%	2,0%	2,2%
<i>ERNC</i>	4,7%	4,1%	7,5%	6,6%
<i>GN</i>	1,8%	3,2%	2,2%	3,1%
<i>P</i>	2,0%	1,8%	1,2%	1,9%

D. Anexo: Cálculo de los coeficientes de Theil

El valor del coeficiente de desigualdad de Theil puede distribuirse en tres componentes: el componente de sesgo (media), atribuido a la diferencia sistemática entre el promedio de los datos reales y estimados; el componente de varianza, que indica la diferencia entre las desviaciones típicas de las tasas de crecimiento reales y estimadas; y la componente de covarianza, que supone que las dos series siguen trayectorias distintas.

Métrica	Definición	Fórmula
MSE	Error cuadrático medio	$MSE = \frac{1}{n} \sum (X_m - X_d)^2$
Estadístico Theil	Descompone el MSE en tres componentes: sesgo (U^M), varianza (U^S) y covarianza (U^C). $U^M + U^S + U^C = 1$	$U^M = \frac{(X_m - X_d)^2}{MSE}$ $U^S = \frac{(S_m - S_d)^2}{MSE}$ $U^C = \frac{2(1 - r)S_m S_d}{MSE}$

N es el total de datos históricos, X_m son los datos simulados y X_d son los datos históricos

E. Anexo: Valores iniciales y límites de los parámetros

Modelo de electrificación:

Initial households	2.001,39 households
◆ Minimum Value	0,00 households
◆ Maximum Value	200.000,00 households
Initial fraction electric	0,05
◆ Minimum Value	0,00
◆ Maximum Value	1,00
Household Addition rate	0,01 per yr
◆ Minimum Value	0,00 per yr
◆ Maximum Value	0,10 per yr
conversion fraction	5,82e-3 households/(yr*c...
◆ Minimum Value	0,00 households/(yr*cont...
◆ Maximum Value	0,05 households/(yr*cont...

Modelo de sustitución

Alfa	0,96 toe/\$
◆ Minimum Value	0,00 toe/\$
◆ Maximum Value	1,00 toe/\$
Premium_Cb	687,47 \$/toe
◆ Minimum Value	-2.000,00 \$/toe
◆ Maximum Value	2.000,00 \$/toe
Premium_ERNC	134,24 \$/toe
◆ Minimum Value	-2.000,00 \$/toe
◆ Maximum Value	1.800,00 \$/toe
Premium_GN	-1.006,20 \$/toe
◆ Minimum Value	-2.000,00 \$/toe
◆ Maximum Value	1.500,00 \$/toe
Premium_Hidro	23,12 \$/toe
◆ Minimum Value	-1.500,00 \$/toe
◆ Maximum Value	600,00 \$/toe
Premium_P	-563,97 \$/toe
◆ Minimum Value	-2.000,00 \$/toe
◆ Maximum Value	1.700,00 \$/toe

VI_EV_Cb	2,88 Mtoe
◆ Minimum Value	1,09 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EV_ERNC	0,01 Mtoe
◆ Minimum Value	0,00 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EV_GN	1,53 Mtoe
◆ Minimum Value	0,65 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EV_Hidro	4,93 Mtoe
◆ Minimum Value	0,00 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EV_P	4,18 Mtoe
◆ Minimum Value	2,51 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EN_Cb	4,90 Mtoe
◆ Minimum Value	0,00 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EN_ERNC	0,43 Mtoe
◆ Minimum Value	0,00 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EN_GN	4,34 Mtoe
◆ Minimum Value	0,00 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EN_Hidro	4,93 Mtoe
◆ Minimum Value	0,00 Mtoe
◆ Maximum Value	5,00 Mtoe
VI_EN_P	19,92 Mtoe
◆ Minimum Value	0,00 Mtoe
◆ Maximum Value	20,00 Mtoe

Bibliografía

- Aracil, J. (1999). On the qualitative properties in system dynamics models. *European Journal of Economic and Social Systems*, 1, 1–18. Retrieved from <http://ejess.edpsciences.org/articles/ejess/abs/1999/01/aracil/aracil.html>
- Bailey, R., Bras, B., & Allen, J. (1998). A Role for Response Surface Based Optimization in System Dynamics Studies. ... *of the Systems Dynamics Society*, 1–10. Retrieved from <http://www.systemdynamics.org/conferences/1998/PROCEED/00076.PDF>
- Barlas, Y. (1996). Formal aspects of model validity and validation in system dynamics. *System Dynamics Review*, 12(3), 183–210. [http://doi.org/10.1002/\(SICI\)1099-1727\(199623\)12:3<183::AID-SDR103>3.0.CO;2-4](http://doi.org/10.1002/(SICI)1099-1727(199623)12:3<183::AID-SDR103>3.0.CO;2-4)
- Dangerfield, B., & Roberts, C. (1996). An overview of strategy and tactics in system dynamics optimization. *Journal of the Operational Research Society*, 47(3), 405–423. Retrieved from <http://www.jstor.org/stable/3010583>
- Duggan, J. (2008). Using System Dynamics and Multiple Objective Optimization to Support Policy Analysis for Complex Systems. *Complex Decision Making*. Retrieved from http://link.springer.com/content/pdf/10.1007/978-3-540-73665-3_4.pdf
- Eksin, C. (2009). *Application of genetic algorithms to analysis and policy design in system dynamics*. Boğaziçi University.
- Fleiter, T., Worrell, E., & Eichhammer, W. (2011). Barriers to energy efficiency in industrial bottom-up energy demand models - a Review. *Renewable and Sustainable Energy Reviews*, 15, 3099–2111. <http://doi.org/10.1016/j.rser.2011.03.025>
- Glover, F., & Kochenberger, G. A. (2010). *Handbook of Metaheuristics*. (M. Gendreau & J.-Y. Potvin, Eds.) (Vol. 146). Boston, MA: Springer US. <http://doi.org/10.1007/978-1-4419-1665-5>
- Graham, A. K., & Ariza, C. A. (2003). Dynamic, hard and strategic questions: using optimization to answer a marketing resource allocation question. *System Dynamics Review*, 19(1), 27–46. <http://doi.org/10.1002/sdr.264>
- Keloharju. (1988). Multi-criteria optimization in system dynamics. In *The 6th International Conference of the System Dynamics Society*. La Jolla, CA USA.
- Keloharju, R., & Wolstenholme, E. F. E. (1988). The basic concepts of system dynamics optimization, 1(1), 65–86. <http://doi.org/10.1007/BF01059889>
- Lyneis, J., & Pugh, A. (1996). Automated vs. “hand” calibration of system dynamics

- models: An experiment with a simple project model. In *Proceedings of the 1996 International System Dynamics conference*. Retrieved from <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Automated+vs.+Hand+Calibration+of+system+dynamics+models+an+experiment+with+a+simple+project#0>
- McSharry, P. (2004). Optimisation of system dynamics models using genetic algorithms. *Submitted to World Bank Report*, (May 2004), 1–14. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.64.4546&rep=rep1&type=pdf>
- Morecroft, J. (2007). *Strategic Modelling and Business Dynamics: A Feedback Systems View*. Chichester, UK: John Wiley & Sons.
- Morecroft, J. D. (1983). System dynamics: Portraying bounded rationality. *Omega*, 11(2), 131–142. [http://doi.org/10.1016/0305-0483\(83\)90002-6](http://doi.org/10.1016/0305-0483(83)90002-6)
- Moxnes, E. (1990). Interfuel Substitution in OECD-European Electricity Production, 6(1), 44–65.
- Ng, T. S., Sy, C. L., & Lee, L. H. (2012). Robust parameter design for system dynamics models: a formal approach based on goal-seeking behavior. *System Dynamics Review*, 28(3), 230–254. <http://doi.org/10.1002/sdr.1475>
- Oliva, R. (2003). Model calibration as a testing strategy for system dynamics models. *European Journal of Operational Research*, 151(3), 552–568. [http://doi.org/10.1016/S0377-2217\(02\)00622-7](http://doi.org/10.1016/S0377-2217(02)00622-7)
- Palisade. (2014). Evolver.
- Ponzo, R., Dyner, I., Arango, S., & Larsen, E. R. (2011). Regulation and development of the Argentinean gas market. *Energy Policy*, 39(3), 1070–1079. <http://doi.org/10.1016/j.enpol.2010.11.009>
- Rahmandad, H., Oliva, R., & Osgood, N. D. (2015). *Analytical method for dynamic modelers*. London., UK.: The MIT Press.
- Rúa, C. (2014). Construcción de la matriz energética nacional a partir de la dinámica de sustitución entre fuentes de energía.
- Schulz, P. G. (2006). Creative Design in Optimization.
- Sterman, J. D. (1983). Appropriate summary statistics for evaluating the historical fit of system dynamics models.
- Sterman, J. D. (2002). All models are wrong: reflections on becoming a systems scientist.

- System Dynamics Review*, 18(4), 501–531. <http://doi.org/10.1002/sdr.261>
- Sweeney, L., & Sterman, J. (2000). Bathtub dynamics: initial results of a systems thinking inventory. *System Dynamics Review*, (September). Retrieved from <http://onlinelibrary.wiley.com/doi/10.1002/sdr.198/abstract>
- Talbi, E.-G. (2009). *Metaheuristics*. Hoboken, NJ, USA: John Wiley & Sons, Inc. <http://doi.org/10.1002/9780470496916>
- Universidad de Alicante. (n.d.). MÉTODOS NUMÉRICOS DE OPTIMIZACIÓN: PROBLEMAS DE OPTIMIZACIÓN SIN RESTRICCIONES. In *Simulación y Optimización de los Procesos Químicos* (pp. 37–76).
- Vanni, T., Karnon, J., & Madan, J. (2011). Calibrating Models in Economic Evaluation. ..., 29(1), 35–49. Retrieved from <http://link.springer.com/article/10.2165/11584600-000000000-00000>
- VENTANA Systems inc. (2010). Vensim.
- Yang, X. (2013). Optimization and Metaheuristic Algorithms in Engineering, (2013), 1–23.
- Yang, X.-S. (2010). *Engineering Optimization*. Hoboken, NJ, USA: John Wiley & Sons, Inc. <http://doi.org/10.1002/9780470640425>