



Grado en Ingeniería en Tecnologías Industriales

Trabajo fin de grado

Reducción de los estados de operación de un sistema eléctrico mediante técnicas de estadística para la planificación de la expansión de la red

Autor

Federico José Giner Conde

Director

Andrés Ramos Galán

Madrid

Agosto 2020

AUTORIZACIÓN PARA LA DIGITALIZACIÓN, DEPÓSITO Y DIVULGACIÓN EN RED DE PROYECTOS FIN DE GRADO, FIN DE MÁSTER, TESINAS O MEMORIAS DE BACHILLERATO

1º. Declaración de la autoría y acreditación de la misma.

El autor D. FEDERICO JOSÉ LINER CONDE

DECLARA ser el titular de los derechos de propiedad intelectual de la obra:

REDUCCIÓN DE LOS ESTADOS DE OPERACIÓN DE UN SISTEMA ELÉCTRICO MEDIANTE TÉCNICAS DE ESTADÍSTICA PARA LA PLANIFICACIÓN DE LA EXPANSIÓN DE LA RED, que ésta es una obra original, y que ostenta la condición de autor en el sentido que otorga la Ley de Propiedad Intelectual.

2º. Objeto y fines de la cesión.

Con el fin de dar la máxima difusión a la obra citada a través del Repositorio institucional de la Universidad, el autor CEDE a la Universidad Pontificia Comillas, de forma gratuita y no exclusiva, por el máximo plazo legal y con ámbito universal, los derechos de digitalización, de archivo, de reproducción, de distribución y de comunicación pública, incluido el derecho de puesta a disposición electrónica, tal y como se describen en la Ley de Propiedad Intelectual. El derecho de transformación se cede a los únicos efectos de lo dispuesto en la letra a) del apartado siguiente.

3º. Condiciones de la cesión y acceso

Sin perjuicio de la titularidad de la obra, que sigue correspondiendo a su autor, la cesión de derechos contemplada en esta licencia habilita para:

- a) Transformarla con el fin de adaptarla a cualquier tecnología que permita incorporarla a internet y hacerla accesible; incorporar metadatos para realizar el registro de la obra e incorporar “marcas de agua” o cualquier otro sistema de seguridad o de protección.
- b) Reproducirla en un soporte digital para su incorporación a una base de datos electrónica, incluyendo el derecho de reproducir y almacenar la obra en servidores, a los efectos de garantizar su seguridad, conservación y preservar el formato.
- c) Comunicarla, por defecto, a través de un archivo institucional abierto, accesible de modo libre y gratuito a través de internet.
- d) Cualquier otra forma de acceso (restringido, embargado, cerrado) deberá solicitarse expresamente y obedecer a causas justificadas.
- e) Asignar por defecto a estos trabajos una licencia Creative Commons.
- f) Asignar por defecto a estos trabajos un HANDLE (URL persistente).

4º. Derechos del autor.

El autor, en tanto que titular de una obra tiene derecho a:

- a) Que la Universidad identifique claramente su nombre como autor de la misma
- b) Comunicar y dar publicidad a la obra en la versión que ceda y en otras posteriores a través de cualquier medio.
- c) Solicitar la retirada de la obra del repositorio por causa justificada.
- d) Recibir notificación fehaciente de cualquier reclamación que puedan formular terceras personas en relación con la obra y, en particular, de reclamaciones relativas a los derechos de propiedad intelectual sobre ella.

5º. Deberes del autor.

El autor se compromete a:

- a) Garantizar que el compromiso que adquiere mediante el presente escrito no infringe ningún derecho de terceros, ya sean de propiedad industrial, intelectual o cualquier otro.
- b) Garantizar que el contenido de las obras no atenta contra los derechos al honor, a la intimidad y a la imagen de terceros.
- c) Asumir toda reclamación o responsabilidad, incluyendo las indemnizaciones por daños, que pudieran ejercitarse contra la Universidad por terceros que vieran infringidos sus derechos e

intereses a causa de la cesión.

- d) Asumir la responsabilidad en el caso de que las instituciones fueran condenadas por infracción de derechos derivada de las obras objeto de la cesión.

6º. Fines y funcionamiento del Repositorio Institucional.

La obra se pondrá a disposición de los usuarios para que hagan de ella un uso justo y respetuoso con los derechos del autor, según lo permitido por la legislación aplicable, y con fines de estudio, investigación, o cualquier otro fin lícito. Con dicha finalidad, la Universidad asume los siguientes deberes y se reserva las siguientes facultades:

- La Universidad informará a los usuarios del archivo sobre los usos permitidos, y no garantiza ni asume responsabilidad alguna por otras formas en que los usuarios hagan un uso posterior de las obras no conforme con la legislación vigente. El uso posterior, más allá de la copia privada, requerirá que se cite la fuente y se reconozca la autoría, que no se obtenga beneficio comercial, y que no se realicen obras derivadas.
- La Universidad no revisará el contenido de las obras, que en todo caso permanecerá bajo la responsabilidad exclusiva del autor y no estará obligada a ejercitar acciones legales en nombre del autor en el supuesto de infracciones a derechos de propiedad intelectual derivados del depósito y archivo de las obras. El autor renuncia a cualquier reclamación frente a la Universidad por las formas no ajustadas a la legislación vigente en que los usuarios hagan uso de las obras.
- La Universidad adoptará las medidas necesarias para la preservación de la obra en un futuro.
- La Universidad se reserva la facultad de retirar la obra, previa notificación al autor, en supuestos suficientemente justificados, o en caso de reclamaciones de terceros.

Madrid, a 25 de AGOSTO de 2020.

ACEPTA

Fdo.



Motivos para solicitar el acceso restringido, cerrado o embargado del trabajo en el Repositorio Institucional:

Declaro, bajo mi responsabilidad, que el Proyecto presentado con el título

REDUCCIÓN DE LOS ESTADOS DE OPERACIÓN DE UN SISTEMA ELÉCTRICO MEDIANTE TÉCNICAS DE

ESTADÍSTICA PARA LA PLANIFICACIÓN DE LA EXPANSIÓN DE LA RED

en la ETS de Ingeniería - ICAI de la Universidad Pontificia Comillas en el


curso académico **CUARTO**..... es de mi autoría, original e inédito y

no ha sido presentado con anterioridad a otros efectos. El Proyecto no es plagio de otro, ni total ni parcialmente y la información que ha sido tomada

de otros documentos está debidamente referenciada.

Fdo.: Federico José Giner Conde

Fecha: **26** / **08** / **2020**



Autorizada la entrega del proyecto

EL DIRECTOR DEL PROYECTO

Fdo.: Andrés Ramos Galán

Fecha: **26** / **08** / **2020**

REDUCCIÓN DE LOS ESTADOS DE OPERACIÓN DE UN SISTEMA ELÉCTRICO MEDIANTE TÉCNICAS DE ESTADÍSTICA PARA LA PLANIFICACIÓN DE LA EXPANSIÓN DE LA RED

Autor

Giner Conde, Federico José,

Director

Ramos Galán, Andrés

Entidad Colaboradora

ICAI – Universidad Pontificia Comillas.

25 de Agosto de 2020

RESUMEN DEL PROYECTO

1. Introducción

La Planificación de la Expansión de la Red o Transmission Expansion Planning (TEP) ha sido siempre uno de los problemas fundamentales en la planificación de todo sistema eléctrico. El objetivo de dicha planificación es conocer el conjunto de inversiones que deben realizarse sobre la red para que los costes totales de operación e inversión sean mínimos. Pretende así optimizar la red, adecuándola a las futuras necesidades de generación, almacenamiento y demanda.

Para ello el TEP se compone, principalmente, de dos partes claramente diferenciadas: el caso de estudio y el modelo. El caso de estudio detalla todos los datos relativos a la generación, demanda y red del año a planificar. El diseño del caso de estudio requiere de un estudio previo de la

incertidumbre o modelado de las condiciones futuras. Por un lado, están las condiciones deterministas, que son aquellas que si bien no se conocen de antemano se pueden considerar como conocidas dado su escaso impacto sobre la toma de decisiones de inversión. El resto de las condiciones futuras se integran dentro del caso de estudio a través de escenarios de operación con su probabilidad de ocurrencia asignada. En [1], por ejemplo, se estudia como integrar en los modelos probabilísticos de TEP la generación eólica a gran escala.

Por otro lado, se tiene el modelo matemático de optimización que ejecuta el caso de estudio y lo optimiza, es decir, determina el funcionamiento óptimo del sistema eléctrico detallado en el caso de estudio. Normalmente el modelo tiene como objetivo optimizar la operación del sistema eléctrico en un año con el acometimiento

de inversiones. Está formado por una función objetivo y un conjunto de restricciones. La función objetivo representa, en este proyecto, los costes de generación (variables, constantes y de energía no servida), los costes de emisión y los costes de inversión. Por otro lado, las restricciones tienen como propósito fijar los límites operacionales.

Aunque en este caso el modelo solo se ha adaptado para realizar el TEP, puede también estarlo para resolver otros problemas relacionados con la toma de decisiones como el Generation Expansion Planning (GEP) –toma de decisiones de inversión en generadores– y la planificación horaria –toma de decisiones de operación del sistema eléctrico–.

Los modelos matemáticos para la resolución de estos problemas se enfrentan en su ánimo de conocer el conjunto de inversiones óptimas del problema en cuestión, con el límite computacional. Las principales fuentes de complejidad computacional son el tamaño del problema, el carácter binario de las variables, las expresiones cuadráticas y el escalamiento numérico. Es precisamente esta complejidad la que inicia una basta discusión en la literatura acerca de qué restricciones hay que integrar en los modelos, cuál es su impacto sobre la solución y cuáles son las formas más compactas y eficaces posibles de expresión, buscando así, en todo momento, un equilibrio entre precisión y complejidad.

No obstante, en muchas ocasiones este compromiso no es suficiente y el problema sigue siendo altamente complejo en cuanto a tamaño. El nivel de precisión requeri-

do hace que el número de estados de operación a considerar en el caso de estudio sea irremediablemente grande y complejo. Por ello se necesitan algoritmos de reducción cuyo propósito es, por medio de la reducción del número de estados, obtener un problema más simple cuyas decisiones de inversión óptimas sean las del problema original. Su tarea es, por tanto, reducir la operación del sistema eléctrico a un número de estados.

Anteriormente a la participación de la energía renovable, los métodos de reducción consistían principalmente en la aplicación de criterios de clustering generalistas como el del nivel de carga. Estos criterios eran correctos en la medida en la que los costes y el nivel de carga estaban altamente correlacionados y en la que la variabilidad en la operación era muy escasa debido al control absoluto sobre los flujos de energía. Con todo esto, la participación de la energía renovable en el mix energético ha complicado considerablemente los criterios y algoritmos de reducción anteriores. Principalmente porque la generación renovable ha introducido una gran variabilidad en los costes del sistema haciendo necesario un mayor número inicial de estados de operación a considerar en los casos de estudio, creciendo aún más el tamaño del problema. Para captar dicha variabilidad, los criterios de reducción, han tenido que aumentar el número de variables con las que caracterizar cada estado de operación.

Ante esta creciente disyuntiva existen diversidad de propuestas en la literatura. Estas se pueden clasificar en dos grandes grupos: los métodos ex-ante, y los méto-

dos ex-post. Los métodos ex-ante seleccionan los estados de operación sin necesidad de realizar una resolución previa, mientras que los ex-post sí realizan dicha resolución. Algunos estudios siguen aplicando los criterios generalistas como en [2, 3], donde se clusteriza en función de la demanda neta, es decir, aquella porción de la demanda que no cubrirá la generación renovable. Los métodos de reducción ex-post emplean una resolución previa del problema para seleccionar los estados representantes de cara a el conjunto de decisiones de inversión buscado. Esta estimación se realiza mediante procesos de relajación, que eliminan una fuente de complejidad que, si bien no es lícita de cara a la precisión exigible en la solución, aporta una información que puede ser útil en cuanto a proximidad a la solución real.

El propósito de este proyecto es aplicar un método de reducción ex-post propuesto en [4] y analizarlo. Dicho estudio ha arrojado resultados excelentes en comparación con otros métodos. Para su análisis se aplicarán otros métodos de reducción generalistas como el del nivel de carga o el de demanda neta. Para ello se desarrollarán dos casos de estudio: uno sin generación renovable o caso A y otro con generación renovable o caso B.

En la Sección 2 se presentará la aplicación de dicha propuesta y se detallarán los dos casos de estudio. En la Sección 3 los resultados obtenidos en el proyecto y en la Sección 4 las conclusiones de éste.

2. Metodología

A continuación, se presentarán ambos casos de estudio así como el procedimiento seguido para la reducción

2.1. Casos de estudio

Ambos casos de estudio se desarrollarán a partir del caso Reliability Test System (RTS) - 1996 (RTS-96) de 73 nodos desarrollado por el Institute of Electrical and Electronics Engineers (IEEE) [5]. Los dos casos son exactamente iguales con la diferencia de que el caso B tiene recursos de generación renovable –hidráulica, solar y fotovoltaica– que el caso A no tiene.

Tanto el caso A como el B tienen 8712 horas de operación en 4356 estados de operación de dos horas de duración cada uno. El enfoque adoptado en el diseño de ambos es el determinista con un único escenario de probabilidad de operación. La fiabilidad del sistema se ha considerado imponiendo un factor de seguridad en las líneas, que modela las posibles contingencias en éstas.

Los casos de estudio están compuestos tablas de contenido. Dichas tablas se pueden dividir principalmente en: generación, demanda y red. En los casos de estudio no se han considerado unidades de carga ni de almacenamiento.

En la Figura 1 se puede ver la distribución de la potencia instalada en ambos casos de estudio, donde la generación renovable se ha modelado como unos perfiles en base a datos del Sistema de Información del Operador del Sistema (SIOS), donde la generación hidráulica, con 18 grupos, representa la generación medida en 18 pro-




Figura 1: Mix de la generación instalada en ambos casos de estudio

vincias de España y la eólica y la solar de la medida global en España. Todo ello correctamente escalado a los límites de potencia instalada.

La demanda se ha modelado en base al pico de demanda anual de 3135 MW, con una demanda media horaria de 37.5 MW comprendida entre 0 y 61.5 MW y distribuida a lo largo de los nodos.

Las líneas que conforman la estructura inicial de la red son líneas en corriente alterna, mientras que los refuerzos o líneas candidatas a invertir en ellas son en corriente continua. Todas las líneas tienen una capacidad de 150 MW, con un factor de seguridad de 0.67 y tensiones 230 y 138 kV.

2.2. Algoritmo de reducción

El algoritmo de reducción tiene como objetivo reducir la operación real del sistema a un número menor de estados de operación para poder obtener las decisiones de inversión. Para ello se necesitan tres pasos.

El primer paso acota el número de inversiones candidatas a acometerse, el segundo separa los estados de operación en dos grupos y saca representantes de cada uno de ellos aplicando criterios de agrupación distintos. El tercer y último paso consiste en realizar la resolución binaria. En la Figura 2 se puede ver un esquema de los pasos a seguir.

Primer paso

Para limitar el conjunto de inversiones candidatas se realiza una resolución previa sin refuerzos candidatos en la que se aumenta la demanda un 20 % y se conforma un conjunto con las líneas con una utilización media superior al 80 %. Dicho conjunto está formado por las líneas candidatas a obtener un refuerzo.

Segundo paso

En primer lugar, se realiza una resolución con las variables de inversión de los refuerzos fijadas a cero para conocer los costes totales en cada estado de operación

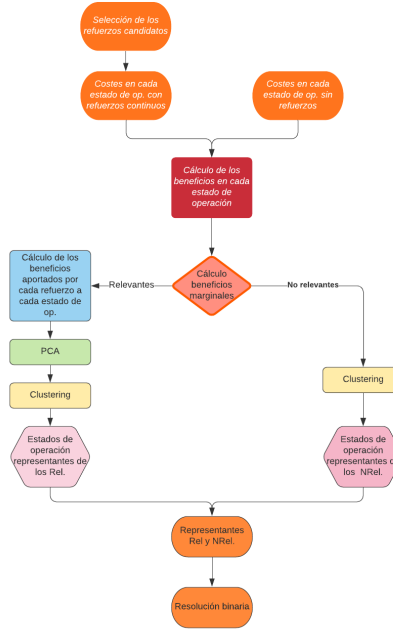


Figura 2: Diagrama de la metodología

en la red sin refuerzos. Seguidamente se realiza la estimación de la operación óptima, relajando las variables de inversión –haciéndolas continuas–.

Estas dos resoluciones permiten realizar en cada estado de operación la resta de los costes estimados como óptimos menos los costes en la red sin refuerzos, obteniéndose la estimación de los beneficios óptimos en cada estado de operación. Como el objetivo es sacar representantes de la operación, se separan los estados en dos grupos –para mejorar la representación y aumentar la eficiencia del algoritmo–. Por un lado, los relevantes: aquéllos cuyo ratio entre beneficio y coste de inversión sea superior a uno y los no relevantes: aquéllos con

ratio menor que uno.

A ambos grupos se les aplican procedimientos de agrupación distintos.

Para cada estado de los relevantes se estima el beneficio aportado para cada refuerzo relajado con la semisuma de la estrategia Put IN one at a Time (PINT) y la estrategia Take One Out at a Time (TOOT)¹, como se puede ver en la Ecuación 1.

$$BR_{sc,p,s,ni,nf,c} = 0,5 \cdot BR_{sc,p,s,ni,nf,c}^{toot} + 0,5 \cdot BR_{sc,p,s,ni,nf,c}^{pint} \quad (1)$$

La estrategia PINT calcula los beneficios de cada refuerzo como la diferencia en los costes entre poner solamente el re-

¹ENTSO-E elaborated a cost and benefit analysis methodology (CBA). URL: <https://tyndp.entsoe.eu/cba/>

fuerzo relajado a evaluar y no poner ningún refuerzo. TOOT en cambio calcula la diferencia entre tener todos los refuerzos relajados menos el evaluado y tener todos los refuerzos relajados.

Con esto se tiene que cada estado de operación relevante tiene x coordenadas, donde cada una es el beneficio aportado por cada refuerzo relajado. Se representan así todos los estados en el espacio de los beneficios aportados por los x refuerzos. Una vez realizada la representación se aplica Principal Component Analysis (PCA) y clustering obteniéndose un número de estados de operación representantes.

Por otro lado, los no relevantes se clustizan directamente en el espacio del ratio entre beneficios y costes de inversión en cada estado de operación. Se sacan así los representantes del grupo de los no relevantes.

Tercer paso

Reducido el tamaño de la operación se ha reducido también el nivel de complejidad computacional asociado. Esto permite ahora mantener el grado de complejidad de las decisiones binarias de inversión. Se resuelve a continuación el modelo con variables de inversión binarias. Para ello se le asignará a cada estado de operación representante la duración en horas de todos los estados de operación a los que representa en su cluster. Así el número de estados se reduce, pero no el de horas de operación. Esta resolución permite obtener el conjunto de decisiones de inversión final.

3. Resultados

En esta sección se presentan los resultados obtenidos en la aplicación de este método de reducción y la consecuente resolución binaria a ambos casos. Donde la versión relajada se refiere al problema original con variables de inversión continuas y la versión binaria el problema reducido en el número de estados y con variables de inversión binarias.

El número de refuerzos candidatos obtenidos en el caso A es de nueve y en el caso B de ocho. La Tabla 1 representa para cada refuerzo candidato el conjunto de inversiones óptimas en la versión relajada, binaria y en el problema original. El nivel de reducción es excelente, con una diferencia entre las funciones objetivo del problema original y en la versión binaria de un 2 % en el caso A y un 1.62 % en el caso B.

Por otro lado, la distribución de los costes totales es muy parecida en la versión relajada y fijando las decisiones binarias en el problema original (Tabla 2).

Por último, se tiene el comportamiento de los refuerzos en los distintos casos de estudio. En la Figura 3 se puede ver cómo se comportan los refuerzos en términos de beneficios con y sin participación renovable.

4. Conclusiones

El objetivo del estudio era aplicar una metodología concreta: la reducción de los estados de operación en función de los beneficios por los refuerzos. Para ello se han planteado otros subobjetivos: el desarrollo de dos casos de estudio con y sin genera-

Sin generación renovable			F.O. Relajada	F.O. Binaria	F.O. Problema original
			928.62 M€	912.94 M€	932.00 M€
			Nº estados de op. 4356	Nº estados de op. 20	Nº estados de op. 4356
Línea candidata			Inversión Relajada	Inversión Binaria	Inversión Binaria
Node_112	Node_123	A21	0.62	1	1
Node_113	Node_123	A22	0.08	0	0
Node_114	Node_116	A23	0.33	0	0
Node_212	Node_223	B21	0.87	1	1
Node_213	Node_223	B22	0.96	1	1
Node_214	Node_216	B23	0.34	1	1
Node_312	Node_323	C21	0.54	1	1
Node_313	Node_323	C22	0.79	1	1
Node_314	Node_316	C23	0.43	0	0

(a) Caso A

Con generación renovable			F.O. Relajada	F.O. Binaria	F.O. Problema original
			738.16 M€	728.69 M€	740.70 M€
			Nº estados de op. 4356	Nº estados de op. 50	Nº estados de op. 4356
Líneas candidatas			Inversión relajada	Inversión binaria	Inversión Binaria
Node_114	Node_116	A23	0	0	0
Node_212	Node_223	B21	0.65	0	0
Node_213	Node_223	B22	0.78	1	1
Node_214	Node_216	B23	0.51	1	1
Node_221	Node_222	B34	1	1	1
Node_312	Node_323	C21	0.32	1	1
Node_313	Node_323	C22	0.66	0	0
Node_314	Node_316	C23	0.56	1	1

(b) Caso B

Tabla 1: Resumen de los resultados


CASO B	C. de operación (M€)	C. de inversión (M€)	C. de emisión (M€)	C. totales (M€)
Versión Relajada	693.43	33.57	11.17	738.17
Versión Binaria	692.02	37.50	11.19	740.71
CASO A	C. de operación (M€)	C. de inversión (M€)	C. de emisión (M€)	C. totales (M€)
Versión Relajada	877.27	37.22	14.11	928.60
Versión Binaria	873.68	45.00	14.15	932.83

Tabla 2: Distribución de los costes


ción renovable y el desarrollo de un algoritmo de reducción. Todos estos objetivos se han cumplido satisfactoriamente, consiguiendo pasar de 4356 estados de operación a 20 en el caso A y 50 en el caso B, manteniendo la distribución de los costes totales de operación y de la generación por tecnologías.

En la selección de los refuerzos candidatos es necesario considerar los flujos renovables. Para ello es de suma relevancia un correcto diseño del caso de estudio, así como la integración de la generación renovable a través de escenarios.

La generación renovable “rompe” el comportamiento de los refuerzos, creando subgrupos de comportamiento. Esto implica que en los criterios de reducción generalistas se haga necesaria una mayor resolución en la representación de los estados de operación para registrar así esa variabilidad en el comportamiento. Esto no ocurría anteriormente a las energías renovables, ya que, como se puede ver en la Figura 3b, el comportamiento era muy uniforme entre las líneas y los refuerzos permitiendo el empleo de criterios generales. Ahora para un mismo nivel de carga pueden existir di-



(a) Caso B



(b) Caso A

Figura 3: Biplot

versidad de comportamientos, y por tanto es necesario distinguirlos con nuevos criterios como el de los beneficios en las líneas.

En casos sin generación renovable los resultados arrojados por el criterio del nivel de carga son mejores que el de los beneficios, mientras que con participación renovable depende del caso de estudio la aplicación del criterio de los beneficios o el de demanda neta. Ambos criterios cometen un error que hay que contrastar y comparar. El primero lo comete al estimar los beneficios asociados a cada refuerzo y el segundo lo hace al ignorar los flujos renovables. Mientras el primero es un método ex-post con una mayor resolución en su criterio y tiempos de computación mayores, el segundo es ex-ante y generalista.

Referencias

- [1] M. Moeini-Aghtaie, A. Abbaspour y M. Fotuhi-Firuzabad. "Incorporating Large-Scale Distant Wind Farms in Probabilistic Transmission Expansion Planning-Part II: Case Studies". En: *IEEE Transactions on Power Systems* 27 (2012), págs. 1594-1601. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2011.2182364. URL: <https://ieeexplore.ieee.org/document/6151863>.
- [2] F. Jimenez y M. D. Webster. "Optimal Selection of Sample Weeks for Approximating the Net Load in Generation Planning Problems". En: *ESD Working Paper Series*. 2013. URL: <http://hdl.handle.net/1721.1/102959>.
- [3] G. Blanford y V. Niemeyer. "Examining the role of renewable resources in a regional electricity model for the US". En: *30th international energy workshop*. 2011.
- [4] Q. Ploussard, L. Olmos y A. Ramos. "An Operational State Aggregation Technique for Transmission Expansion Planning Based on Li-

- ne Benefits”. En: *IEEE Transactions on Power Systems* 32.4 (2017), págs. 2744-2755. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2016.2614368. URL: <https://ieeexplore.ieee.org/document/7582509>.
- [5] C. Grigg y col. “The IEEE Reliability Test System-1996. A report prepared by the Reliability Test System Task Force of the Application of Probability Methods Subcommittee”. En: *IEEE Transactions on Power Systems* 14.3 (1999), págs. 1010-1020. ISSN: 1558-0679. DOI: 10.1109/59.780914. URL: <https://ieeexplore.ieee.org/document/780914>.

SNAPSHOT REDUCTION WITHIN THE OPERATION OF AN ELECTRIC SYSTEM THROUGHOUT STATISTICAL TECHNIQUES FOR THE TRANSMISSION EXPANSION PLANNING

1 Introduction

Transmission Expansion Planning (TEP) has always been one of the fundamental problems in the planning of any electrical system. The objective of this planning is to know the set of investments that must be made on the network so that the total costs of operation and investment are minimal. In this way, it aims to optimise the network, adapting it to future generation, storage and demand needs.

For this purpose, the TEP is mainly composed of two clearly differentiated parts: the case study and the model. The case study details all the data relating to generation, demand and the network for the year to be planned. The design of the case study requires a prior study of the uncertainty or modelling of future conditions. On the one hand, there are the deterministic conditions, which are those which, although not known in advance, can be considered as known given their scarce impact on investment decision making. The rest of the future conditions are integrated into the case study through operating scenarios with their assigned probability of occurrence. In [1], for example, is studied

how to integrate large scale wind generation into probabilistic models.

On the other hand, there is the mathematical model of optimization that executes the case study and optimizes it, that is, it determines the optimal functioning of the electrical system detailed in the case study. Normally the model aims to optimize the operation of the electrical system in one year with the investment undertaking. It consists of an objective function and a set of constraints. The objective function represents, in this project, the generation costs (variable, constant and unserved energy), the emission costs and the investment costs. On the other hand, the restrictions are intended to set operational limits.

The model can be also design for tackling other problems related with the decision-making issues such as the Generation Expansion Planning (GEP) and the unit commitment. Usually the model's complexity leads to a computational burden due to the size of the problem, the non-linear behaviour of the problem, and numerical issues. This hallmark triggers a vast discussion about which constraints should be considered in the model and which is the most compact and efficient

formulation, always looking after a deal between complexity and accuracy.

However, in many cases this commitment is not enough and the problem remains highly complex in terms of size. The level of accuracy required makes the number of operating states to be considered in the case study irretrievably large and complex. This is why reduction algorithms are needed. Their purpose is, by reducing the number of states, to obtain a simpler problem whose optimal investment decisions are those of the original problem. Their task is therefore to reduce the operation of the electrical system to a number of states.

Prior to the involvement of renewable energy, reduction methods consisted mainly of applying generalist clustering criteria such as load level. These criteria were correct insofar as costs and load level were highly correlated and insofar as there was very little variability in operation due to the absolute control over energy flows. With all this, the participation of renewable energy in the energy mix has considerably complicated the previous criteria and reduction algorithms. Mainly because renewable generation has introduced a great variability in the system costs making necessary a greater initial number of operation states to be considered in the case studies, increasing even more the size of the problem. In order to capture this variability, the reduction criteria have had to increase the number of variables with which to characterise each state of operation.

Faced with this growing dilemma, there is a diversity of proposals in the literature. These can be classified into two large groups: ex-ante methods, and ex-post

methods. The ex-ante methods pre-select the states of operation without the need to make a previous resolution, while the ex-post methods do make such a resolution. Some studies continue to apply generalist criteria such as in [2, 3], where it is clustered according to net demand, i.e., that portion of demand that will not be covered by renewable generation. Ex-post reduction methods use a prior resolution of the problem to select representative states for the set of investment decisions sought. This estimation is carried out by means of relaxation processes, which eliminate a source of complexity which, although it is not licit in view of the precision required in the solution, provides information which may be useful in terms of proximity to the real solution.

The purpose of this project is to apply an ex-post reduction method proposed in [4] and analyse it. This study has shown excellent results compared to other methods. Other generalist reduction methods such as load level or net demand will be applied for analysis. Two case studies will be developed for this purpose: one without renewable generation or case A and one with renewable generation or case B.

section 2 will present the application of this proposal and detail the two case studies. section 3 will present the results obtained in the project and section 4 the conclusions of the project.

2 Methodology

Both case studies and the procedure followed for reduction will be presented below

2.1 Case-study

Both case studies will be developed from the 73-node Reliability Test System (RTS) - 1996 (RTS-96) case developed by the Institute of Electrical and Electronics Engineers (IEEE) [5]. Both cases are exactly the same with the difference that case B has renewable generation resources - hydraulic, solar and photovoltaic - and case A does not.

Both cases A and B have 8712 operating hours in 4356 operating states of 2 hours duration each. The approach adopted in the design of both is the deterministic one with a single operating probability scenario. The reliability of the system has been considered by imposing a safety factor on the lines.

The case studies are composed of tables of contents. These tables can be divided mainly into: generation, demand and network. In the case studies, neither load nor storage units have been considered.

In the Figure 1 it can be seen the distribution of the installed power in both case studies, where the renewable generation has been modeled as profiles based on the System Operator Information System (SIOS) data where the hydraulic generation, with 18 groups, represents the generation measured in 18 provinces of Spain and the wind and solar of the global measurement in Spain. All this correctly scaled to the limits of the installed power.

The demand has been modeled based on the annual peak demand of 3135 MW, with an average hourly demand of 37.5 MW between 0 and 61.5 MW and distributed along the nodes.

The lines that make up the initial struc-

ture of the network are CA lines, while the reinforcements or lines that are candidates for investment are DC lines. All lines have a capacity of 150 MW, with a safety factor of 0.67 and voltages of 230 and 138 kV.

2.2 Reduction algorithm

The reduction algorithm aims to reduce the actual operation of the system to a smaller number of operating states in order to obtain investment decisions. This requires three steps. The first step limits the number of investment candidates to be undertaken, the second separates the operating states into two groups and draws representatives from each of them by applying different clustering criteria. The third and final step is to carry out the binary resolution. In the Figure 2 it can be seen a diagram of the steps to follow.

First step

In order to limit the set of candidate investments, a prior resolution is made without candidate reinforcements in which the demand is increased by 20% and a set is made up with the lines with an average saturation of more than 80%. This set is made up of the lines that are candidates for reinforcement.

Second step

First, a resolution is made with the investment variables of the reinforcements set to 0 in order to know the total costs in each state of operation in the system without reinforcements. Next, the optimum operation is estimated, relaxing the investment variables - making them continuous.




Figure 1: Mix of the installed generation in both case studies

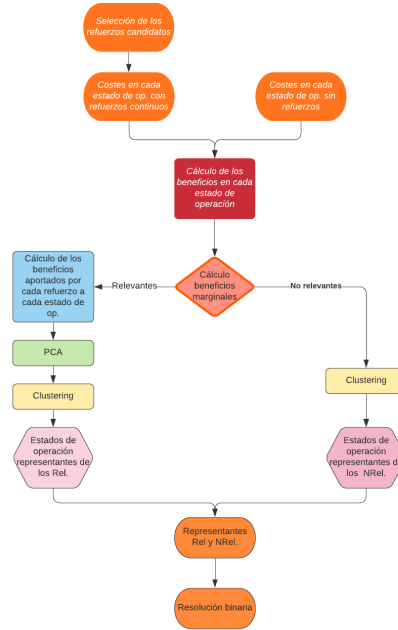


Figure 2: Flow diagram

These two resolutions allow the subtraction of the costs estimated as optimal minus the costs in the system without reinforcements in each state of operation, obtaining the estimate of the optimal benefits

in each state of operation. As the objective is to obtain the representatives from the operation, the states are separated into two groups - in order to improve the representation and increase the efficiency of

the algorithm. On the one hand, the relevant ones: those whose ratio between profits and investment cost is greater than 1 and the non-relevant ones: those with a ratio of less than 1.

Different grouping procedures are applied to both groups.

For each state of the relevant ones, the benefit provided for each relaxed reinforcement is estimated with the semisum of the Put IN one at a Time (PINT) strategy and the Take One Out at a Time (TOOT) strategy ¹, as can be seen in the Equation 1.

$$BR_{sc,p,s,ni,nf,c} = 0.5 \cdot BR_{sc,p,s,ni,nf,c}^{toot} + 0.5 \cdot BR_{sc,p,s,ni,nf,c}^{pint} \quad (1)$$

The PINT strategy calculates the benefits of each reinforcement as the difference in costs between putting only the relaxed reinforcement to evaluate and not putting any reinforcement at all. TOOT instead calculates the difference between having all the relaxed reinforcements except the one evaluated and having all the relaxed reinforcements.

With this, each state of operation has x coordinates where each one is the benefit contributed by each relaxed reinforcement. Thus, all the states are represented in the space of the benefits contributed by the x reinforcements. Once represented in that space, Principal Component Analysis (PCA) and clustering are applied, thus obtaining the representatives of the system operation.

The non-relevant ones, on the other

hand, are clustered directly in the space of the ratio between profit and investment costs in each operating state. The group representatives are thus removed from the non-relevant ones.

Third step

Reducing the size of the operation has also reduced the level of associated computational complexity, this now allows the degree of complexity of binary investment decisions to be maintained. The model with binary inversion variables is now solved. For it, each operation state representative will be assigned the duration in hours of all the operation states that it represents in its cluster. This way the number of states is reduced but not the number of operation hours.

This resolution makes it possible to obtain the final set of investment decisions

3 Results

This section presents the results obtained in the application of this reduction method and the consequent binary resolution in both cases. Where the relaxed version refers to the original problem with continuous inversion variables and the binary version refers to the reduced problem in the number of states and with binary inversion variables.

The number of candidate reinforcements obtained in case A is nine and in case B eight. The Table 1 represents for each candidate reinforcement the optimal set of investments in the relaxed, binary

¹ENTSO-E elaborated a cost and benefit analysis methodology (CBA). URL: <https://tyndp.entsoe.eu/cba/>

Sin generación renovable			F.O. Relajada	F.O. Binaria	F.O. Problema original
			928.62 M€	912.94 M€	932.00 M€
			Nº estados de op. 4356	Nº estados de op. 20	Nº estados de op. 4356
Línea candidata			Inversión Relajada	Inversión Binaria	Inversión Binaria
Node_112	Node_123	A21	0.62	1	1
Node_113	Node_123	A22	0.08	0	0
Node_114	Node_116	A23	0.33	0	0
Node_212	Node_223	B21	0.87	1	1
Node_213	Node_223	B22	0.96	1	1
Node_214	Node_216	B23	0.34	1	1
Node_312	Node_323	C21	0.54	1	1
Node_313	Node_323	C22	0.79	1	1
Node_314	Node_316	C23	0.43	0	0

(a) Case A

Con generación renovable			F.O. Relajada	F.O. Binaria	F.O. Problema original
			738.16 M€	728.69 M€	740.70 M€
			Nº estados de op. 4356	Nº estados de op. 50	Nº estados de op. 4356
Líneas candidatas			Inversión relajada	Inversión binaria	Inversión Binaria
Node_114	Node_116	A23	0	0	0
Node_212	Node_223	B21	0.65	0	0
Node_213	Node_223	B22	0.78	1	1
Node_214	Node_216	B23	0.51	1	1
Node_221	Node_222	B34	1	1	1
Node_312	Node_323	C21	0.32	1	1
Node_313	Node_323	C22	0.66	0	0
Node_314	Node_316	C23	0.56	1	1

(b) Case B

Table 1: Summary of the results

version and in the original problem. The level of reduction is excellent, with a difference between the target functions of the original problem and the binary version of 2.0 % in case A and 1.62 % in case B.

On the other hand, the distribution of the total costs is very similar in the relaxed version and fixing the binary decisions in the original problem (Table 2).

Finally, the behavior of the reinforcements in the different case studies is obtained. In the Figure 3 it can be seen how the reinforcements behave in terms of benefits with and without renewable participation.

4 Conclusions

The aim of the study was to apply a specific methodology: the reduction of oper-

ating states according to the benefits of reinforcements. To this end, other subobjectives were considered: the development of two case studies with and without renewable generation and the development of a reduction algorithm. All these objectives have been satisfactorily met, increasing the number of operating states from 4356 to 20 in case A and 50 in case B, maintaining the distribution of total operating costs and generation by technology.

In the selection of candidate reinforcements, it is necessary to consider renewable flows. For this purpose, a correct design of the case study is of utmost importance, as well as the integration of renewable generation through scenarios.

The renewable generation “breaks” the behaviour of reinforcements, creating behavioural subgroups. This implies that in

CASO B	C. de operación (M€)	C. de inversión (M€)	C. de emisión (M€)	C. totales (M€)
Versión Relajada	693.43	33.57	11.17	738.17
Versión Binaria	692.02	37.50	11.19	740.71
CASO A	C. de operación (M€)	C. de inversión (M€)	C. de emisión (M€)	C. totales (M€)
Versión Relajada	877.27	37.22	14.11	928.60
Versión Binaria	873.68	45.00	14.15	932.83

Table 2: Distribution of costs




Figure 3: Biplot

the generalist reduction criteria a greater resolution in the representation of the operation states is necessary to register this variability in behavior. This did not happen before to renewable energies, since, as it can be seen in the Figure 3b, the behaviour was very uniform between the lines and the reinforcements allowing the use of general criteria. Now, for the same level of load, there can be a diversity of behaviour, and therefore it is necessary to distinguish them with new criteria such as that of the benefits on the lines.

In cases without renewable generation, the results produced by the load level criterion are better than those obtained from the benefit criterion, while with renewable participation the application of the benefits or

net demand criterion depends on the case study. Both criteria make a mistake that must be contrasted and compared. The first is made when estimating the benefits associated with each reinforcement and the second is made when ignoring renewable flows. While the first is an ex-post method with a higher resolution in its criteria and longer computation times, the second is ex-ante and generalist.

References

- [1] M. Moeini-Aghaie, A. Abbaspour, and M. Fotuhi-Firuzabad. "Incorporating Large-Scale Distant Wind Farms in Probabilistic Transmission Expansion Planning-Part II:

- Case Studies”. In: *IEEE Transactions on Power Systems* 27 (2012), pp. 1594–1601. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2011.2182364. URL: <https://ieeexplore.ieee.org/document/6151863>.
- [2] F. Jimenez and M. D. Webster. “Optimal Selection of Sample Weeks for Approximating the Net Load in Generation Planning Problems”. In: ESD Working Paper Series. 2013. URL: <http://hdl.handle.net/1721.1/102959>.
- [3] G. Blanford and V. Niemeyer. “Examining the role of renewable resources in a regional electricity model for the US”. In: *30th international energy workshop*. 2011.
- [4] Q. Ploussard, L. Olmos, and A. Ramos. “An Operational State Aggregation Technique for Transmission Expansion Planning Based on Line Benefits”. In: *IEEE Transactions on Power Systems* 32.4 (2017), pp. 2744–2755. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2016.2614368. URL: <https://ieeexplore.ieee.org/document/7582509>.
- [5] C. Grigg et al. “The IEEE Reliability Test System-1996. A report prepared by the Reliability Test System Task Force of the Application of Probability Methods Subcommittee”. In: *IEEE Transactions on Power Systems* 14.3 (1999), pp. 1010–1020. ISSN: 1558-0679. DOI: 10.1109/59.780914. URL: <https://ieeexplore.ieee.org/document/780914>.

Agradecimientos

*A Él por todo.
A mis padres por el ejemplo de lucha, superación y constancia.
Sin ellos yo no sería nada.*

*A mis amigos,
en especial a Gonzalo Estrán Buyo por su disponibilidad y sus
amplios conocimientos en Python que ha compartido conmigo
en todo momento*

Índice general

1. Planteamiento	1
1.1. Planificación de la inversión y de la operación	1
1.2. Planificación de la inversión de la red	1
1.3. El tratamiento de la incertidumbre y los casos de estudio	2
1.4. Modelo	4
1.5. Reducción	6
2. Estado de la técnica	9
2.1. Selección de líneas candidatas	10
2.2. Métodos de reducción	10
2.2.1. Ex-ante	11
2.2.2. Ex-post	11
2.3. Propuesta	13
3. Descripción del modelo desarrollado	17
3.1. Objetivos y especificación	17
3.2. Casos de estudio	18
3.2.1. Generación	19
3.2.2. Demanda	21
3.2.3. Generación variable renovable	22
3.2.4. Red	23
3.2.5. Reserva	24
3.3. Modelo	25
3.3.1. Nomenclatura	25
3.3.2. Variables	26
3.3.3. Función objetivo	27
3.3.4. Restricciones	28
3.4. Obtención de las variables de inversión	31
3.4.1. Primer paso	31
3.4.2. Segundo paso	32
3.4.3. Tercer paso	39

4. Presentación y análisis de resultados	41
4.1. Resultados	41
4.1.1. Primer Paso	42
4.1.2. Segundo Paso	43
4.1.3. Tercer Paso	51
4.2. Análisis de los resultados	53
4.2.1. Comportamiento de los refuerzos	54
4.2.2. Efecto de las estrategias TOOT, PINT	57
4.2.3. Caso A sin generación renovable	58
4.2.4. Caso B con generación renovable	59
4.3. Estudio económico	61
4.3.1. Inversiones y gastos	61
4.3.2. Proyección del dinero	62
4.3.3. Amortización	63
4.3.4. Coste normalizado de la generación	63
5. Conclusiones	65
5.1. Conclusiones metodología	65
5.2. Conclusiones sobre resultados	66
5.3. Recomendaciones para futuros estudios	68
A. Anexo I: Desarrollo sostenible	71
A.1. Alineación con los objetivos ODS	71
A.2. Cuantificación	72
B. Anexo II: Recursos empleados	75
B.1. Recursos de cómputo	75
B.1.1. Características del ordenador	75
B.2. Aplicaciones	75
B.2.1. Python	75
B.2.2. GIT	76
B.2.3. Revistas científicas	76
B.2.4. Otros	76
B.2.5. Latex	77
Bibliografía	79

Índice de figuras

2.1. Aproximación de las curvas de demanda y generación renovable con uno, cinco y diez días representativos [15]	12
2.2. Soluciones LP (relajación) y MILP	13
2.3. Costes totales obtenidos con la aplicación de diferentes algoritmos de reducción [17]	14
2.4. Diagrama de flujo de la propuesta [17]	15
3.1. Distribución de la generación por tecnologías en los dos casos	20
3.2. Mix de la generación instalada en ambos casos de estudio	21
3.3. Muestra de nudos con sus valores de demanda en MW	22
3.4. Nivel de demanda en MW para cada hora del año	23
3.5. Perfiles de generación renovable en MW para cada hora del año	24
3.6. Diagrama de la metodología a seguir	32
3.7. Ejemplo de la dirección que siguen las componentes principales	37
3.8. Proceso iterativo de k-means clustering	37
3.9. QE frente al número de clusters	38
4.1. Tanto por uno de varianza explicada por cada una de las componentes principales	44
4.2. QE frente al número de clusters en los relevantes	45
4.3. Estados de operación relevantes en el espacio de los beneficios aportados por los refuerzos principales	47
4.4. QE frente al número de clusters en los no relevantes	48
4.5. Densidad de la clusterización en los 363 días	50
4.6. Energía generada en GWh en el caso A por tecnologías	52
4.7. Energía generada en GWh en el caso B por tecnologías	53
4.8. Grupos de correlación en las variables del caso B	55
4.9. Grupos de correlación en las variables del caso A	56
4.10. Beneficio en M€ aportado por cada refuerzo en cada estado de operación según TOOT y PINT	57
4.11. Resultados de reducción con el nivel de carga	59

4.12. Clasificación de los costes presentes en la planificación de ambos casos de estudio	61
--	----

Índice de tablas

3.1. Capacidad de los grupos	21
3.2. Resumen de los costes de generación	22
4.1. Conjunto de líneas candidatas en ambos casos de estudio	42
4.2. Resultados de la versión relajada	43
4.3. Número de estados de operación relevantes y no relevantes en cada caso	44
4.4. Representantes en el grupo de los relevantes	46
4.5. Representantes en el grupo de los no relevantes	49
4.6. Comparación del nivel de reducción en funciones objetivo, ecuaciones, variables y tiempo	50
4.7. Tiempos de cómputo en segundos del algoritmo de reducción desarrollado	51
4.8. Resumen de los resultados de inversión	51
4.9. Beneficios asociados a las variables de inversión binarias	52
4.10. Matrices de correlación entre los refuerzos	57
4.11. Comparación de los resultados en las inversiones entre el criterio de los beneficios y de la demanda neta con el mismo nivel de reducción: 50 estados de operación	60
4.12. Costes de operación emisión e inversión	62

Siglas

ODS Objetivos de Desarrollo Sostenible. 71

APPA Asociación de Empresas de Energía renovables. 71

GEP Generation Expansion Planning. 1, 5, 21, 25, 68, 69, 76

IEEE Institute of Electrical and Electronics Engineers. 18, 66, 76

IIT Instituto de Investigación Tecnológica. 25

LCOE Levelized Cost of Electricity. 63

MCS Monte-Carlo Simulation. 3

MILP Mixed Integer Linear Problem. 12

PCA Principal Component Analysis. 14, 15, 36, 41, 44, 59

PINT Put IN one at a Time. 18, 35, 36, 43, 44, 51, 53, 57–59, 67, 69

RTS-96 Reliability Test System (RTS) - 1996. 18

SE4ALL Energía Sostenible Para Todos. 71

SIOS Sistema de Información del Operador del Sistema. 23

TEP Transmission Expansion Planning. 1, 2, 4, 5, 9, 10, 17, 21, 25, 27, 65, 69, 76

TOOT Take One Out at a Time. 18, 35, 36, 43, 44, 51, 53, 57–59, 67, 69

Capítulo 1

Planteamiento

1.1. Planificación de la inversión y de la operación

Dado el tamaño industrial de una red eléctrica, el número de decisiones posibles que se pueden realizar sobre ella son innumerables. Algunas de estas decisiones son ineludibles y tienen como objeto minimizar los costes totales del sistema eléctrico cumpliendo unos requerimientos y condiciones, como la cobertura de la demanda y el uso de tecnologías renovables. Existen dos naturalezas de decisión que articulan tres problemas fundamentales en toda red eléctrica compleja: las decisiones de inversión y las decisiones de operación.

La planificación de la expansión de la red o Transmission Expansion Planning (TEP) y la planificación de la expansión de la generación o Generation Expansion Planning (GEP) son los dos problemas principales relacionados con la toma de decisiones de inversión. Mientras el TEP busca qué líneas construir para reducir los costes totales, el GEP realiza el mismo ejercicio pero con generadores. Las variables que tienen asociadas estos problemas son variables binarias de inversión que traen una gran complejidad a la resolución de los modelos de optimización.

En cuanto a la toma de decisiones de operación, se encuentra el tercer problema: la planificación de la operación de la generación y de la red. Este problema es conocido como la planificación horaria y determina los despachos de generación de las unidades para cumplir con todos los requerimientos al mínimo coste.

1.2. Planificación de la inversión de la red

Este proyecto se centra en el problema TEP, cuyo objetivo es preparar y adecuar la red a los nuevos cambios en la generación, almacenamiento y demanda de

energía, con el objetivo de minimizar los costes. La creciente descarbonización y la introducción de generación renovable en el mix energético ha complicado mucho los modelos de TEP obligando a introducir nuevos planteamientos y formas de abordar el problema. Esto se debe a que parte de esa energía renovable –eólica y solar principalmente– se ha convertido en una fuente ingestible para el operador del sistema; es decir, una energía variable e incierta, cuya naturaleza debe tenerse en cuenta en el modelo.

En este capítulo se explican las distintas partes de las que consta el TEP con el objetivo de proporcionar una visión general del problema y para encuadrar el objeto de este proyecto: los métodos de reducción de los estados de operación de la red. Para ello es necesario primero explicar cuáles son sus partes y qué funciones desempeñan. Este capítulo se dividirá en tres secciones: tratamiento de la incertidumbre y caso de estudio, el modelo matemático y la reducción del problema. Todas estas partes se encuentran relacionadas unas con otras articulando así la planificación de la expansión de la red.

El TEP es un problema de optimización multicriterio que pretende saber cuándo, dónde y cuántas nuevas líneas hay que construir, para servir a la demanda al mínimo coste en un sistema eléctrico a 10 años vista. El objetivo del TEP es, por tanto, minimizar los costes totales del sistema. De tal forma que el planificador quiere conocer cuáles son las inversiones que debe hacer sobre la red para que los costes totales en el año a planificar sean mínimos. Estas inversiones se plantean sobre líneas de refuerzo.

El operador para poder conocer cuáles son las inversiones que debe realizar tiene que, en primer lugar, diseñar el caso de estudio para después optimizarlo aplicando un modelo matemático. Sin embargo, es posible que necesite reducir las dimensiones del problema, ya que tal y como se plantea es irresoluble con los recursos actuales de computación. Empleará así algoritmos de reducción que le permitan resolver el problema y obtener las decisiones de inversión. Estos tres elementos, además de articular la planificación, dependen unos de otros siguiendo una cadena.

1.3. El tratamiento de la incertidumbre y los casos de estudio

La planificación de la red requiere de diseñar en un caso de estudio el sistema eléctrico futuro que se quiere planificar. No obstante, tanto la estructura de dicho sistema como las condiciones de generación, demanda y almacenamiento a diez años vista no se pueden conocer con seguridad. Este hecho implica analizar la variabilidad de dicha incertidumbre y su impacto sobre el conjunto de decisiones

de inversión final. Así, todas estas condiciones son inciertas, no obstante, algunas de ellas pueden modelarse como deterministas, esto es, se suponen conocidas, ya sea por su escasa variabilidad o porque se estima que no afectarán considerablemente al conjunto de decisiones de inversión final. El resto de las condiciones que si pueden impactar sobre el conjunto de decisiones se modelan como estocásticas o probabilísticas, es decir, que se modelan con una probabilidad. Cuando se habla de modelo determinista [1, 2] se refiere a aquel caso de estudio que se diseña considerando que todas las condiciones futuras de la red son deterministas y asumiendo que se produce el peor de los escenarios posibles. No obstante, hoy en día con la participación de la generación renovable, la incertidumbre introducida en la operación ha hecho que incluso la determinación del peor de los escenarios sea una tarea muy complicada [3]. Los modelos probabilísticos, en cambio, tratan aquellas condiciones cuya variabilidad estiman relevante de cara a los resultados de inversión, con incertidumbre. Esto es una tarea compleja que requiere de estudios estadísticos para sacar la distribución de probabilidad de fenómenos como la generación eólica. En [4], por ejemplo, se estudia la forma de incorporar la generación eólica en modelos probabilísticos. Otra clasificación común en la literatura [5, 6] es aquella que divide las condiciones inciertas como:

- *Long-term uncertainties*: esta incertidumbre se asocia al pico de la demanda y a la capacidad de generación. Es una incertidumbre que no tiene probabilidad asignada.
- *Short-term uncertainties*: con la participación de la energía renovable los fenómenos meteorológicos han condicionado la generación y el almacenamiento. Este tipo de incertidumbres son estocásticas y se asocian por ejemplo a las condiciones eólicas e hidrológicas.

Una vez modelada la incertidumbre hay que integrarla dentro de los casos de estudio. El caso de estudio contiene todos los datos relativos al sistema eléctrico en cuestión, normalmente generación, red y demanda. La forma de integrar la componente probabilística es a través de escenarios de probabilidad. De tal forma, ya no se considera un único año de operación sino varios posibles escenarios con su probabilidad asignada. Para ello se generan muestras siguiendo determinadas distribuciones a través de métodos de simulación como Monte-Carlo Simulation (MCS). El número de escenarios de operación puede llegar a ser relativamente grande, lo cual a su vez supone un problema de tamaño de cara a resolver el problema de planificación de expansión o de operación que se plantee.

Normalmente el caso de estudio abarca un año entero de operación segmentado bien sea en horas, días o semanas. Es por ello por lo que debe llegarse a un compromiso entre complejidad y precisión a la hora de desarrollar los casos de estudio. El problema que surge en este punto en el diseño de los casos de estudio es

que la introducción de las energías renovables ha obligado a diseñar con una mayor resolución en los estados de operación, haciendo necesario trabajar con modelos de operación horarios o bihorarios para considerar dicha variabilidad, aumentando así considerablemente el tamaño del problema.

Tal y como ha demostrado la técnica la consideración o no consideración de los escenarios estocásticos (es decir, escenarios cuyas variables tienen asociadas distribuciones de probabilidad) afecta considerablemente a la toma de decisiones en la planificación; es más, los resultados obtenidos considerando estas incertidumbres se acercan más al óptimo real –si se hace adecuadamente– [1, 7]. Por ello, es muy importante crear casos de estudio probabilísticos basados en estudios meteorológicos y que reflejen de manera precisa y sólida las posibilidades de la generación renovable. Los escenarios de probabilidad normalmente están más asociados a la generación renovable, dada su considerable participación y variabilidad en los sistemas eléctricos. En España, por ejemplo, la cobertura de la demanda anual de la energía eólica ha sido en el 2019 de un 20.9 % según el informe¹ del mismo año de Red Eléctrica de España. Los perfiles de generación renovable se suelen obtener en base a históricos y estudios estadísticos. La variabilidad de la demanda suele estar relacionada con fenómenos demográficos y económicos fácilmente estimables. Normalmente se diseñan varios perfiles de generación para el año con sus probabilidades asignadas. La generación de los grupos cuya potencia es controlable y gestionable se deja en forma de variable para que el modelo de optimización establezca cuáles son sus valores óptimos.

1.4. Modelo

El modelo TEP es un modelo matemático de optimización. Está formado por una función objetivo y una serie de restricciones. El caso de estudio es sobre el que se aplica el modelo, y del que el modelo coge todos los datos y parámetros para optimizar la red que representa el caso de estudio.

Como ya se ha dicho el objetivo es hacer mínimos los costes totales. Estos se componen de distintos tipos. Los más importantes son los costes de inversión, así como los de operación. Los costes a considerar pueden ser aparte de los de inversión y operación, los de emisiones. Esto permite obtener además de las variables de decisión de inversión en nuevas líneas de transporte también las relacionadas con la operación y las emisiones. En [2] se muestra el impacto de la consideración de estos costes.

Después se fijan las restricciones. Aquí se abre una vasta discusión acerca de cuál es la forma más compacta y adecuada para la formulación. Generalmente se

¹Avance ISE 2019. URL:https://www.ree.es/sites/default/files/11_PUBLICACIONES/Documentos/InformesSistemaElectrico/2020/Avance_ISE_2019.pdf

incluyen restricciones asociadas al flujo de cargas, a la red, al almacenamiento y a la generación. Hay algunos estudios interesantes en los que se discuten algunas de estas restricciones de forma que sean lo más compactas posibles [8, 9].

En cuanto a las variables que define el modelo se dividen en dos grupos, las variables de inversión y las de operación. En lo que respecta a las variables de inversión existe una por cada refuerzo, unidad de generación y de almacenamiento a considerar. En función de qué variables de inversión se encuentren en el problema se habla de TEP y/o GEP. Las variables de inversión de líneas o refuerzos corresponden al TEP y las variables de inversión referentes a los generadores candidatos al GEP. Por otro lado, están las variables de operación. Las variables de operación son, principalmente, las de generación de cada grupo, las de planificación horaria, las de carga de cada unidad de almacenamiento y las de reserva a subir y bajar. Éstas tienen una variable distinta para cada unidad y estado de operación. Esto es muy importante porque hay que distinguir entre horas de operación y estados de operación. Las variables de operación se definen para cada estado de operación. Un estado de operación tiene una duración asignada. A lo largo de un estado la operación del sistema entero se considera constante en todas sus variables de operación. Si bien cada estado puede tener un número de horas de duración asignadas, el número de horas totales por todos los estados de operación deben ser constantes. En este proyecto se desarrolla un método para reducir el número de estados de operación, pero manteniendo una representación precisa de la operación del sistema de manera que las principales decisiones de inversión en la red son las mismas que con el conjunto original de estados de operación.

El principal problema que surge en este punto y que condiciona en gran medida los modelos de planificación de la red es la capacidad computacional. Esto se debe a la complejidad del problema que puede hacerlo computacionalmente inabordable²:

1. El tamaño del problema:
 - El número de estados de operación.
 - El tamaño de la red y generación.
2. El carácter binario de las variables de inversión.
3. Expresiones cuadráticas.
4. El escalado numérico.

Así se suele proceder a algunas relajaciones en las restricciones como aproximar el flujo AC por DC. Esta aproximación suele ser común en proyectos a largo plazo.

²*Modeling: Best practices & techniques*. Pág. 4. URL:<https://www.gurobi.com/pdfs/user-events/2016-frankfurt/Best-Practices.pdf>

Estas relajaciones pueden, según algunos autores, incurrir en subóptimos [2] y hay que considerarlas detenidamente así como analizar su impacto. Según [10] las principales desventajas de los modelos DC frente a los AC son que a cambio de perder complejidad computacional desprecia los flujos de reactiva y difícilmente modela las pérdidas reales.

1.5. Reducción

Como ya se ha visto, existen relajaciones internas al modelo matemático para limitar la barrera computacional. No obstante, muchas veces no es suficiente y la misma barrera computacional sigue resultando un problema, ya sea por las variables de inversión, el tamaño de la red y la generación o el número de estados de operación. Aquí es donde entran los algoritmos de reducción, que tratan de hacer el problema computacionalmente tratable reduciendo el nivel de complejidad asociado al número de estados de operación del problema. Esto añadido al número de variables presentes hace que el número de ecuaciones y variables fácilmente sobrepase los dos millones. Por tanto, si se pretende obtener las variables de inversión binarias y dado que este nivel de complejidad no se puede eliminar por el propio carácter de las decisiones –que no admiten otro carácter que el binario–, es conveniente reducir las dimensiones del problema.

Con todo esto hay tres formas de reducir las dimensiones del problema: reducir el número de estados de operación, reducir el tamaño de la red o generación y limitar el número de inversiones posibles.

El número de inversiones que se pueden realizar sobre una red real representan una cantidad desmesurada e ingestible. Si se considerasen todas, el número de variables de inversión sería muy elevado. Es por esto por lo que se puede reducir el número de variables de inversión haciendo una selección de cuáles son las inversiones más importantes a considerar. Así queda reducido el número de líneas candidatas en las que invertir. Esto hay que resolverlo con una serie de algoritmos. El peligro al que se enfrentan estos algoritmos es a pasar por alto una inversión óptima.

Otra forma de reducir el tamaño del problema es reducir el número de estados de operación, y en consecuencia, también, el número de variables de operación. Esto no equivale a reducir el número de horas de operación sino los niveles de comportamiento operacional distintos. Todos los estados de operación juntos deben durar la misma cantidad de horas. Esto por supuesto implica reducir la granularidad. Hay dos formas de hacerlo: una homogéneamente y otra selectivamente. La forma homogénea se hace a través de un *timestep* –que es precisamente lo que dura cada estado de operación–. Así se puede hacer que todos los estados en vez de durar una hora duren dos o tres horas. Sin embargo, esto tiene un límite. Se puede redu-

cir homogéneamente mientras se considere una variabilidad suficiente como para explicar la generación renovable. En casos sin generación renovable no se necesita tanta resolución y esta reducción homogénea se puede aplicar más profusamente. La otra forma es la selectiva y es en la que se centrará este proyecto: consiste en distinguir los estados de operación más relevantes de cara a las decisiones de inversión en la red de forma que optimizar con ellos arroje una solución muy parecida a la que se obtendría, si se pudiese, con todos los estados de operación. Los algoritmos de reducción, por tanto, pretenden seleccionar los estados de operación.

Precisamente la introducción de la generación renovable a través de escenarios de probabilidad en los casos de estudio ha complicado los algoritmos de reducción de la operación. Esto se debe a que con anterioridad a la participación de la energía renovable los algoritmos de reducción seleccionaban los estado de operación con mayores y menores niveles de carga, ya que eran los que mayores y menores costes de operación tenían asociados respectivamente. Sin embargo, con la participación de la energía renovable se necesitan algoritmos de reducción que puedan registrar la variabilidad que dichas energías han trasladado a los costes de operación. Se hace necesario así ampliar la resolución de los métodos de reducción.

Esta variabilidad viene impuesta por el carácter ingestible de parte de la generación renovable –en concreto la eólica y la solar fotovoltaica– y por prevalecer en el mercado frente a las energías no renovables por no tener costes variables. La generación renovable ingestible no está controlada: no se sabe con determinación dónde, cuándo y con qué intensidad lucirá el sol y soplará el viento, y por tanto cuánta energía de este tipo se volcará a la red. Hay otra forma de generación renovable que sí es gestionable *a priori* y es la hidráulica regulable; el operador de la instalación tiene un control absoluto sobre su generación: puede decidir, en última instancia, cuánto turbinar. Hay otras formas de hidráulica como la minihidráulica cuya generación depende de la afluencia del río y por tanto es ingestible.

Los métodos de reducción, además, deben reducir la operación del sistema con escenarios de probabilidad, ya que la generación renovable requiere a menudo de esta formulación.

La calidad del algoritmo depende de la robustez que presente ante distintos sistemas eléctricos. Es decir, que se pueda aplicar con un carácter general. No todos los algoritmos de reducción son preferibles en todos los casos de estudio. Así en cada caso es conveniente enfrentar las distintas propuestas de reducción y ver cuál es más pertinente.

En el Capítulo 2 se explicará todo esto con mucho más detalle.

Capítulo 2

Estado de la técnica

Como ya se ha explicado anteriormente, con la introducción de las energías renovables los modelos de TEP se han complicado considerablemente. Esto se debe fundamentalmente a que la generación renovable ha introducido mucha variabilidad en los costes de operación.

El principal obstáculo al que se enfrenta el TEP es la barrera computacional. El conjunto de posibles inversiones que se pueden realizar sobre una red más el carácter binario de las propias decisiones eleva la complejidad del problema considerablemente, haciendo muy costosa su resolución. Con todo esto hay tres formas de afrontar el problema:

- Reducir la barrera computacional, aumentando así la capacidad de resolución.
- Reducir el tamaño del problema:
 - a)* Reducir el número de variables de inversión.
 - b)* Reducir el número de estados de operación.
 - c)* Reducir el número de generadores y líneas de la red.

Dejando a un lado el desarrollo computacional y dada su evidente limitación en redes reales, es precisamente el desarrollo de algoritmos para reducir el tamaño del problema una de las actuales vías de investigación. Este proyecto se centra en los algoritmos de reducción de los estados de operación. No obstante, existen algoritmos para reducir el número de inversiones posibles o el tamaño de la red. La aplicación de éstos es independiente entre sí pudiendo darse que en algunos casos de estudio sea necesaria la aplicación conjunta de ellos.

En este capítulo se pretende revisar los algoritmos de reducción de los estados de operación, así como los de selección de líneas candidatas. Así pues se introducirá la técnica que se aplicará a dos casos de estudio en el Capítulo 3.

2.1. Selección de líneas candidatas

La limitación que impone la capacidad computacional no solo implica reducir el tamaño de la operación con los algoritmos de reducción, sino también acotar el número de inversiones posibles. En el TEP estas inversiones candidatas son nuevos corredores –líneas que unen nodos que previamente no estaban conectados– y líneas de refuerzo a líneas existentes. Es, por tanto, inviable computacionalmente considerar todas las posibles líneas y refuerzos a invertir en una red real. Es por esto por lo que además de desarrollar algoritmos para reducir la operación del sistema también se desarrollan algoritmos para seleccionar las líneas candidatas. Algunos son muy sencillos como por ejemplo resolver la operación de la red sin ningún refuerzo adicional, y a partir del nivel de saturación de las líneas establecer el conjunto de refuerzos candidatos. No obstante, existen algunos estudios más sofisticados. Generalmente este conjunto de líneas candidatas se construye a partir de la experiencia del operador del sistema que suele proponer nuevos corredores combinado con la propuesta de líneas de refuerzo en corredores existentes por parte de algoritmos.

Más allá de la saturación de las líneas existen otros algoritmos más sofisticados. En [11], por ejemplo, se resuelve iterativamente el despacho económico de cada refuerzo y en base a ello se establece el set de candidatos. En [12] se propone un método de identificación de candidatos combinado con una reducción en su número para garantizar la optimización y la aportación de información de los refuerzos candidatos para facilitar la toma de decisiones por parte del operador.

2.2. Métodos de reducción

La reducción de los estados de operación es esencial y se ha abordado principalmente con dos métodos: ex-ante [13, 14, 15] y ex-post [16, 17]. El objetivo de ambos es fácilmente planteable: seleccionar los estados de operación representativos del año operacional. El método ex-ante difiere del ex-post en que preselecciona los estados de operación con los que reducirá las dimensiones del problema sin realizar previamente una estimación de la operación óptima del sistema. Sin embargo, el ex-post realiza dicha estimación en base a la cual luego aplicará la reducción.

Como se ha visto anteriormente las fuentes de complejidad de un problema de optimización son varias. Entre ellas se encuentra el tamaño del problema. Si un modelo de optimización tiene 20 restricciones definidas para cada hora del año, generador, línea y nudo, el número de ecuaciones y variables puede ser del orden de millones. Es necesario entonces reducir este número de ecuaciones y variables si relajar el carácter binario de las variables de inversión es inviable. Una primera aproximación a reducir el problema es pasar de 8760 estados y una hora por cada

estado a 4380 estados y dos horas por cada estado de operación. Esta sería la reducción homogénea. Sin embargo, esto, como ya se ha explicado, solamente se puede hacer hasta cierto punto, ya que se necesita mantener un nivel de resolución horario suficiente como para explicar la variabilidad presente en el problema. Por tanto se necesita reducir con inteligencia, esto es, selectivamente, mediante procesos estadísticos.

La mayoría de los métodos de reducción emplean clustering para la reducción de la red. No obstante, lo que varía de un método a otro es, a parte de la metodología ex-ante o ex-post, el criterio de distancia. El criterio utilizado en la agrupación de las horas en escenarios de operación es lo que cambia entre los algoritmos dentro de una misma metodología.

2.2.1. Ex-ante

Los métodos de reducción ex-ante permiten preseleccionar los estado de operación en base al caso de estudio desarrollado. Es el método clásico que se ha venido empleando hasta ahora. Anteriormente a las energías renovables, el criterio de reducción más antiguo empleado era el de nivel de carga [18]. Este criterio reducía los estados de operación en el espacio de la demanda total. Los representantes obtenidos lo eran también de los costes totales ya que, al no haber energías renovables, los costes de operación –fundamentalmente en forma de combustible– eran directamente proporcionales a la energía generada.

Hoy en día esta propuesta ha derivado hacia el criterio de la demanda neta [13, 14] donde se clusteriza con aquella parte de la demanda que se estima que las renovables no van a cubrir.

Frente a la necesidad de considerar la variabilidad introducida por las renovables, recientes estudios proponen nuevos espacios de representación. En [15], por ejemplo, cada día de operación se representa en el espacio de la demanda y generación renovable horaria. Después mediante clustering y normalización saca los representantes correspondientes para aproximar las curvas de demanda y generación renovable y luego optimizarlas, de forma que queda reducida la operación. En la Figura 2.1 se puede ver dicho ajuste. Este algoritmo reduce la operación en función de datos históricos de la participación renovable, así como de la demanda.

2.2.2. Ex-post

Por otro lado, se tiene el método ex-post, que parte de una estimación de la operación del sistema. Es decir, obtiene información de la operación e inversión óptima para luego clusterizar. Esta información se aprovecha para determinar los estados de operación más relevantes de cara a obtener las mismas decisiones de




Figura 2.1: Aproximación de las curvas de demanda y generación renovable con uno, cinco y diez días representativos [15]

inversión en la red que si se resolviese el problema original. La forma de obtener esta información es muy diversa, existiendo diferentes propuestas.

En [16] se propone un método de reducción de escenarios de operación. El criterio agrupa según la distancia al escenario medio o esperado del set inicial. Así, este método, para realizar la reducción, estima la operación óptima esperada y agrupa en función de la distancia a dicha solución.

Otra forma de estimar la operación óptima del sistema es con una resolución relajada de las variables de decisión del problema. La relajación de variables enteras es un procedimiento común, principalmente a la hora de resolver Mixed Integer Linear Problems (MILPs). Se puede encontrar en los conocidos algoritmos de “Branch and Bound” y “Branch and cut” que ponen al servicio métodos de relajación de variables para resolver problemas más complicados. Estos procedimientos están orientados a obtener la solución entera a través de procedimientos de acotamiento y ramificación y son ampliamente utilizados en la literatura [19]. Así, la idea es relajar un problema a través de sus variables para obtener una solución de operación óptima, que si bien no es la solución que se está buscando se aproxima a ésta; todo esto con un esfuerzo computacional mucho menor al haber quitado un grado de complejidad. Esta solución se convierte en un punto de partida, desde el que, con los procesos de ramificación y acotamiento se llega a la solución real. En la Figura 2.2 ¹ se puede ver que la solución del problema linealizado (LP) se encuentra relativamente cerca de la solución que se busca.

En algunos casos de estudio los algoritmos de “Branch and Bound” y “Branch and cut” no son suficientes para obtener la solución buscada. Así, lo que se hace es aprovechar la solución del LP para, en vez de resolver el problema original, reducir

¹Imagen obtenida de Wikipedia, URL: <https://de.wikipedia.org/wiki/Schnittebenenverfahren>

su tamaño. Se obtiene así un problema distinto al original y más sencillo, en el que sí se puede obtener las variables de inversión. Precisamente esto es lo que se va a aplicar en este proyecto y lo que se propone en [17].

Los algoritmos ex-post dependen de la calidad de la estimación. El error de integralidad o *integrality gap* (IG) mide precisamente la bondad de la estimación o su calidad. En la Ecuación 2.1 se puede ver su formulación, donde mín_{int} es el mínimo real y mín_{rel} el mínimo aproximado.

$$IG = \frac{\text{mín}_{int} - \text{mín}_{rel}}{\text{mín}_{int}} \quad (2.1)$$

El método ex-post estima la operación óptima de demanda y generación de la red con la solución del LP. En este caso se seguirá esta última metodología, y de la que en definitiva depende la eficacia del algoritmo a desarrollar.




Figura 2.2: Soluciones LP (relajación) y MILP

2.3. Propuesta

Este proyecto aplica y analiza la técnica de reducción propuesta en [17]. Se trata de un método de reducción ex-post que reduce el número de estados de operación del sistema en función de los beneficios incrementales asociados a las líneas de refuerzo candidatas. La aplicación de éste permite obtener las variables de inversión en un problema similar al original.

Este algoritmo aprovecha la solución del LP del problema original para reducir selectivamente la operación del mismo. Para ello emplea procesos estadísticos de reducción como Principal Component Analysis (PCA) y clustering. En la Figura 2.3 se presentan los resultados obtenidos en dicho estudio en un caso base de 24 nudos. Como se puede ver, los costes a los que conduce este método son menores que los del resto de algoritmos.




Figura 2.3: Costes totales obtenidos con la aplicación de diferentes algoritmos de reducción [17]

A continuación se detallarán los pasos seguidos que plantea el algoritmo, y que se pueden ver resumidos en la Figura 2.4.

Estimación de la operación óptima Se estima la operación óptima resolviendo un problema lineal que corresponde con la versión LP del problema original. Se relajan las variables de inversión binarias, simplificando así el problema, y se resuelve. Ya que obtener las variables de inversión binarias a partir de dicha solución mediante “Branch and Bound” o “Branch and cut” sigue resultando computacionalmente muy costoso se emplea dicha solución para reducir las dimensiones del problema. Esta reducción se realiza en los estados de operación, obteniendo así un problema distinto al original y más simple. Las soluciones de inversión de este último, esta vez sí, binarias, se consideran como una estimación del conjunto de decisiones de inversión buscado.

Separación de los estados de operación en relevantes y no relevantes

Para garantizar una buena representación de la operación y aumentar la rapidez y eficiencia se divide el conjunto inicial de estados en el grupo de los relevantes y no




Figura 2.4: Diagrama de flujo de la propuesta [17]

relevantes. Esta separación se realiza en función del ratio entre beneficio y coste de inversión. El beneficio de cada estado se computa como la diferencia entre los costes totales con los refuerzos continuos y sin refuerzos. Los costes de inversión se distribuyen uniformemente entre el número inicial de estados.

Computación de los beneficios en cada refuerzo Es en los estados de operación relevantes en los que se computan los beneficios que aporta cada refuerzo en cada estado de operación; los no relevantes se llevan directamente a clustering. De tal forma que cada estado relevante queda representado en el espacio de los beneficios aportados por cada refuerzo.

Reducción de las dimensiones del problema Se aplica PCA en los estados relevantes para reducir el espacio de los beneficios. Esto se hace precisamente porque los refuerzos continuos que propone la solución pueden ser muchos y por tanto es aconsejable explicar la variabilidad de los datos con el menor número de dimensiones posibles.

Clustering Se sacan los representantes en cada grupo de estados de operación: los relevantes y los no relevantes. Los no relevantes se clusterizan en el espacio del ratio beneficio-coste mientras que los relevantes en el de las componentes principales. Cada estado de operación representante tendrá asignado el número de horas

contenidas en su cluster correspondiente.

Resolución binaria Se resuelve el problema reducido con las variables de decisión de inversión –esta vez sí– binarias. Este problema es distinto del original pero representativo de su operación.

En el Capítulo 3 se desarrollará el código para una vez obtenida la estimación de la operación del problema LP reducir las dimensiones del problema

Capítulo 3

Descripción del modelo desarrollado

En el capítulo primero, se ha descrito el problema general del TEP y cómo se articula a través de un modelo de optimización y un caso de estudio, para posteriormente explicar el objeto de los métodos de reducción.

En el segundo capítulo se ha realizado un breve repaso a lo largo de algunas propuestas de métodos de reducción de la operación. Con todo esto se ha introducido la propuesta final de reducción que se va a aplicar y a analizar: un método de reducción en función de los beneficios incrementales por las líneas.

En este capítulo se desarrollarán los dos casos de estudio sobre los que se aplicará la reducción: uno con presencia de recursos de generación renovable y otro sin ella. Por otro lado, se presentará el modelo que se va a emplear. Por último, se describirá paso por paso el desarrollo del algoritmo de reducción en base a los beneficios por las líneas de refuerzo.

3.1. Objetivos y especificación

El desarrollo de los casos de estudio y del algoritmo persigue la consecución de una serie de objetivos. Dichos objetivos se dividen en dos: los objetivos de desarrollo y aplicación y los objetivos de análisis.

Los objetivos que se atenderán en este capítulo son los siguientes:

- Desarrollar un caso base representativo con dos versiones.
 - Una versión que incluya generación renovable.
 - Una versión sin generación renovable.
- Desarrollo del algoritmo de reducción de estados de operación.
 - Separar los estado de operación relevantes de los no relevantes.
 - Computar los beneficios por las líneas en los relevantes.
 - Aplicar Análisis de componentes principales.
 - Aplicar clustering.
- Análisis.
 - Análisis del comportamiento de los refuerzos en presencia de generación renovable.
 - Análisis de las estrategias Take One Out at a Time (TOOT) y Put IN one at a Time (PINT).
 - Análisis del efecto del algoritmo en el caso sin generación renovable.
 - Análisis de la consideración de la generación renovable con su respectiva intermitencia y efecto del algoritmo.

3.2. Casos de estudio

El caso en el que se apoyará este trabajo es el caso **Reliability Test System (RTS) - 1996** (RTS-96) cuyos datos proporciona el Institute of Electrical and Electronics Engineers (IEEE) [20]. El caso RTS-96 representa una red de 73 nodos y 8712 horas de operación. A partir de él se generarán dos versiones sobre las que se aplicará el algoritmo: un caso sin generación renovable o caso A (como el caso original RTS-96) y otro con generación renovable o caso B. Ambos casos desarrollados se pueden visualizar en **github**¹. El objetivo al diseñar ambos casos es probar el algoritmo de reducción de estados de operación en redes con generación

¹Final Project URL:https://github.com/fedeginer/final_project

renovable y sin generación renovable y analizar su impacto en comparación con otros algoritmos.

El *timestep* de ambos casos de estudio será de dos horas. Por tanto, habrá inicialmente 4356 estados de operación. Esta es la reducción homogénea que se aplica en el modelo y que se ha comentado en la Sección 1.5. Cada estado quedará definido por un escenario de operación, un año, un mes, un día y una hora.

En ambos casos de estudio se seguirá un enfoque determinista, es decir, que se asume todas las condiciones como deterministas y que la variabilidad en el sistema no afectará al conjunto de decisiones de inversión finales. La fiabilidad del sistema (en este caso las contingencias de las líneas) se considera de forma aproximada con el factor de seguridad de las líneas.

Cada caso se compone de una serie de tablas de datos en formato “csv” que contienen toda la información necesaria para resolver el problema de optimización.

Podemos distinguir 5 grandes bloques de datos: la generación, la demanda, la red, la generación variable y la reserva de operación.

3.2.1. Generación

Los datos de generación se estructuran con un diccionario que contiene todas las etiquetas de todas las unidades de generación de la red. Cada unidad de generación tiene dos etiquetas (excepto la unidad “solar” y la unidad “eólica”). La primera hace referencia al ID de la tecnología (que además coincide con la capacidad de generación de la misma) y la segunda al número ID que la distingue del resto de unidades de la misma tecnología. Cada tecnología queda definida en función de su combustible, ciclo termodinámico y tamaño de sus unidades. Las unidades de generación están distribuidas a lo largo de los nodos de la red. No en todos los nodos hay generación.

Las tecnologías presentes en los casos de estudio desarrollados se dividen en renovables y no renovables. Dentro de las renovables se encuentran la minihidráulica, la solar-fotovoltaica y la eólica. El resto de las tecnologías son no renovables. En la Figura 3.1 se tiene un esquema con la distribución de la generación por unidades en el caso desarrollado.

En la tabla de datos de generación se especifican, en función de la tecnología, las capacidades de generación de las unidades, así como los costes de generación.

El número de unidades y la capacidad de generación de cada una se puede ver en la Tabla 3.1. Por otro lado la distribución de la generación por tecnologías se pueden ver en la Figura 3.2.

En cuanto a los costes, estos se pueden ver resumidos en la Tabla 3.2. Como se puede ver para cada tecnología se definen una serie de costes:

- Costes variables.




Figura 3.1: Distribución de la generación por tecnologías en los dos casos

- Costes constantes (asociados al acoplamiento de la unidad).
- Costes de operación y mantenimiento.
- Costes de emisión.
- Costes de arranque.
- Costes de parada.

Los costes variables son aquéllos que dependen de la cantidad de energía producida. En realidad, es un coste de combustible: cuanta más energía se genera mayor es el coste variable. Este coste es el principal en los costes de operación.

Tecnología	ID	Combustible	Número de unidades	Capacidad por unidad (MW)	Capacidad total (MW)
Vapor/Petróleo	100	Petróleo	9	100	900
Vapor/Petróleo	12	Petróleo	15	12	180
Vapor/Carbón	155	Carbón	12	155	1860
Vapor/Petróleo	197	Petróleo	9	197	1773
Turbina de combustión/Petróleo	20	Petróleo	12	20	240
Vapor/Carbón	350	Carbón	3	350	1050
Nuclear	400	LWR	6	400	2400
Hidráulica	50	-	18	50	900
Vapor/Carbón	76	Carbón	12	76	912
Eólica	-	-	1	150	150
Solar	-	-	1	200	200

Tabla 3.1: Capacidad de los grupos




Figura 3.2: Mix de la generación instalada en ambos casos de estudio

Como se puede ver este coste solamente es 0 en las tecnologías renovables, lo que hace que éstas entren primero en la cobertura de la demanda y, consecuentemente, introduzcan una gran variabilidad en la operación del sistema. En la Sección 4.3 se puede ver un esquema con la distribución de los costes en función de su tecnología.

Se han considerado 0 los costes constantes y los de parada. Los costes constantes representan el coste constante en el que se incurre por de acoplar la unidad al mínimo técnico.

El modelo, del que se habla más adelante, está adaptado para la GEP además de la TEP. En ninguno de los casos se definirán generadores candidatos ya que el método de reducción está orientado al TEP.

3.2.2. Demanda

La demanda se ha fijado en función de los porcentajes de pico de demanda anual, definidos para cada mes, día y hora. El pico anual se ha establecido como 3135 MW. Esta demanda está definida para cada estado de operación del año y

Coste Unidad	Variable €/MWh	Constante €	O&M €/MWh	Emisión €/MWh	StartUp €	ShutDown €
OilSt_U100	131.48	0	3	1.31	6172.98	0
OilSt_U12	155.51	0	0	0.00	801.88	0
CoalSt_U155	42.99	0	6	1.63	3058.75	0
OilSt_U197	133.36	0	3	1.31	9207.93	0
OilCT_U20	148.86	0	0	1.24	75.60	0
CoalSt_U350	44.77	0	6	1.63	16084.90	0
Nuc_U400	2317.60	0	0	0.00	0.00	0
Hyd_U50	0.00	0	0	0.00	0.00	0
CoalSt_U76	50.16	0	6	1.63	3003.79	0
Eólica	0.00	0	0	0.00	0.00	0
Solar	0.00	0	0	0.00	0.00	0

Tabla 3.2: Resumen de los costes de generación

en cada nodo de la red.

De los 73 nodos de la red solamente 51 tiene demanda. En la Figura 3.3 se puede observar una muestra de esos 51 nodos con sus demandas medias, máximas y mínimas. Se ha añadido el nodo con la máxima demanda anual.




Figura 3.3: Muestra de nudos con sus valores de demanda en MW

Por otro lado, es importante también considerar la demanda horaria y ver que es mucho menor que la potencia instalada. En este caso la potencia demandada media horaria es de 37.5 MW, variando entre 61.5 MW y 0 MW. Por tanto, la demanda horaria es mucho menor que la potencia instalada que resulta ser 10565 MW.

3.2.3. Generación variable renovable

La generación variable renovable solamente está presente en el caso B. Se han contemplado tres recursos de generación renovable: eólico, solar fotovoltaico e hidráulico. Están conectados a nodos separados y tienen una potencia instalada de




Figura 3.4: Nivel de demanda en MW para cada hora del año

140 MW, 200 MW y 900 MW respectivamente. Los perfiles de generación hidráulica², eólica³ y solar fotovoltaica⁴ se han obtenido del Sistema de Información del Operador del Sistema (SIOS) y han sido escalados y adaptados a los niveles de demanda y generación del caso RTS-96.

Los perfiles de generación solar y eólica corresponden a la generación medida en España –sistema peninsular y no peninsular– en 2019; por otro lado, los perfiles de generación hidráulica corresponden a la generación hidráulica de 18 provincias del sistema peninsular en el 2019 con toda clase de perfiles. En la Figura 3.5 se pueden ver representados los perfiles de generación solar y eólica.

3.2.4. Red

En cuanto a la red se tienen por un lado las líneas que conforman la estructura inicial de la red y por otro lado las líneas de refuerzo candidatas. Hay un total de 120 líneas todas ellas con una capacidad de 150 MW, un factor de seguridad de 0.67 y tensiones de 230 y 138 kV. En ambos casos de estudio se considerarán

²Generación medida hidráulica, URL: https://www.esios.ree.es/es/analisis/10035?vis=1&start_date=01-01-2019T00%3A00&end_date=31-12-2019T23%3A00&compare_start_date=31-12-2018T00%3A00&groupby=hour

³Generación medida eólica, URL: https://www.esios.ree.es/es/analisis/10037?vis=1&start_date=01-01-2019T00%3A00&end_date=31-12-2019T23%3A00&compare_start_date=31-12-2018T00%3A00&groupby=hour

⁴Generación medida solar fotovoltaica, URL: https://www.esios.ree.es/es/analisis/1161?vis=1&start_date=01-01-2019T00%3A00&end_date=31-12-2019T23%3A50&compare_start_date=31-12-2018T00%3A00&groupby=hour




Figura 3.5: Perfiles de generación renovable en MW para cada hora del año

pérdidas en las líneas como un 2 % del flujo. Las líneas candidatas son de tipo refuerzo a líneas ya existentes en el modelo, por tanto, no se considerarán dentro de este conjunto corredores nuevos. Cada línea está formada por el nodo inicial, el final y un circuito –ya que puede haber varias en paralelo–.

Las líneas candidatas tienen asociado un coste de inversión de 100 millones de euros (es un coste medio independiente de la longitud de cada línea) con una tasa de carga fija del 7.5 %. Dichas líneas se ha asumido que son de corriente continua. El conjunto de líneas candidatas se forman con los algoritmos de selección de líneas descritos en la Sección 2.1. En este caso el conjunto se obtendrá con la aplicación de un método muy sencillo basado en la saturación de las líneas. Para ello se aplicará al caso base sin refuerzos un incremento de la demanda del 20 %. Los refuerzos candidatos serán para aquellas líneas con una utilización anual media mayor del 80 % teniendo en cuenta que la red suele tener un ratio de utilización del orden de 30 %.

El resto de las líneas de la red son de corriente alterna. La diferencia principal de cara al modelo es que para estas líneas está definida la 2ª ley de Kirchhoff de tensiones, mientras que, para las candidatas, por ser en corriente continua, no aplica.

3.2.5. Reserva

La reserva a subir y a bajar son unos perfiles de generación que demanda el operador del sistema para la regulación del mismo en cada estado de operación. En este caso se ha definido como un 2 % de la demanda total en cada estado,

siguiendo las indicaciones oficiales de **Red Eléctrica de España** ⁵. La reserva a subir y a bajar serán iguales.

3.3. Modelo

Los casos de estudio mencionados anteriormente se adaptarán para ser ejecutados con el modelo openTEPES versión 1.6.32⁶. El modelo es una versión pública y disponible on-line.

El modelo openTEPES está diseñado para realizar simultáneamente el TEP, GEP y la planificación horaria. No obstante, el objetivo de este proyecto es proponer un método de reducción de la operación del sistema para determinar las variables de inversión en el TEP. Precisamente porque el método de reducción se dirige a resolver el TEP no se considerarán generadores candidatos en los casos de estudio. En cuanto a la planificación horaria se ignorará el carácter binario en el modelo de las variables de la planificación horaria en todo momento, de forma que serán siempre variables relajadas. Se asume por tanto que dicho carácter binario no afecta considerablemente a la toma de decisiones final.

En esta sección se especificarán la función objetivo y las restricciones que se aplicarán con el modelo openTEPES a los casos de estudio. Así mismo se detallarán las modificaciones añadidas al modelo por requerimiento del algoritmo de reducción.

3.3.1. Nomenclatura

A continuación se definen los índices y los parámetros:

- w Escenario de operación.
- p Año de operación.
- n Hora de operación.
- g Generador.
- i, j Nodos.
- c Circuito contenido entre los nodos i, j .

⁵Resolución de 13 de julio de 2006, de la Secretaría General de Energía, por la que se aprueba el procedimiento de operación 1.5 «Establecimiento de la reserva para la regulación frecuencia-potencia». URL: [https://www.boe.es/eli/es/res/2006/07/13/\(1\)](https://www.boe.es/eli/es/res/2006/07/13/(1))

⁶A. Ramos, E. Alvarez y S. Lumbreras. *Open Generation and Transmission Operation and Expansion planning Model with RES and EES*. Instituto de Investigación Tecnológica (IIT). URL: <https://pascua.iit.comillas.edu/aramos/opentepest/index.html>

- P_w Probabilidad asignada al escenario de operación w .
- DUR_n Duración de la hora de operación n [h].
- CV_g Coste variable del generador g [€/MWh].
- CSU_g Coste de arranque del generador g [€/MW].
- $CENS$ Coste de la energía no servida [€/MWh].
- ER_g Tasa de emisión de CO2 del generador g [tonelada/MW].
- CFT_{ijc} Costes anuales de inversión en el refuerzo ijc [M€].

3.3.2. Variables

El modelo openTEPES presenta diversas variables ⁷. Estas se pueden dividir en dos grupos: las variables binarias y las variables continuas. A continuación, se hace una clasificación de éstas:

- Variables continuas:
 - Variables de generación:
 - a) Generación de cada unidad: gp_{wpng} .
 - b) Generación 2º bloque de cada unidad: p_{wpng} .
 - Variables de reserva:
 - a) Reserva a subir en cada unidad: ur_{wpng} .
 - b) Reserva a bajar en cada unidad: dr_{wpng} .
 - Variable energía no servida en cada nodo i : ens_{wpni} .
 - Variables de la red:
 - a) Pérdidas de cada línea ijc : l_{wpnijc} .
 - b) Flujo por cada línea ijc : f_{wpnijc} .
 - c) Ángulo de tensión de cada nodo i : Θ_{wpni} .
 - Variables de costes:
 - a) Costes variables [€]: $\sum_{wpng} (P_w \cdot DUR_n \cdot CV_g \cdot gp_{wpng} + CSU_g \cdot su_{wpng}) + \sum_{wpni} P_w \cdot DUR_n \cdot CENS \cdot ens_{wpni}$.

⁷Formulación matemática del modelo. URL: <https://pascua.iit.comillas.edu/aramos/openTEPES/MathematicalFormulation.html>

- b) Costes de emisión [€]: $\sum_{wpng} P_w \cdot CO2_{cost} \cdot ER_g \cdot gp_{wpng}$.
- c) Costes fijos [M€]: $\sum_{ijc} CFT_{ijc} \cdot ict_{ijc}$.

■ Variables binarias:

- Planificación horaria de cada unidad:
 - a) Acoplamiento al mínimo técnico: uc_{wpng} .
 - b) Arranque: su_{wpng} .
 - c) Parada: sd_{wpng} .
- Inversión refuerzos en cada línea candidata ijc : ict_{ijc} .

Las variables que no son de inversión se definen en cada estado de operación wpn , donde w es el escenario, p el año y n la hora del año.

Las variables binarias son fuente de complejidad por tanto el modelo permite relajarlas en su definición. Esto es fundamental porque toda la reducción y la selección de inversiones candidatas estriba en el carácter relajado de las variables de inversión.

Las variables que más interesan para la reducción son las variables de costes totales en cada estado de operación y las de inversión relajadas. Esas son las dos principales que se emplearán. A partir de las variables de flujo por cada una de las líneas se puede conocer la saturación de éstas en cada estado de operación.

3.3.3. Función objetivo

Como se ha visto, el objetivo del TEP es conocer el conjunto final de decisiones de inversión que hagan los costes totales mínimos. La función objetivo será por tanto la minimización de los costes totales. Los costes totales considerados son:

- Costes de operación
- Costes de inversión (sólo en refuerzos de líneas)

Se puede ver en el análisis económico, en la Figura 4.12 un desglose de todos los costes que se van a considerar, exceptuando a los de inversión en generadores candidatos. Los costes de emisión dependen de la tecnología y del combustible empleado. La idea de considerar estos costes es tener en cuenta los costes de CO_2 en el mercado de emisiones. Es decir, la consideración de éstos parece pertinente de acuerdo con la Agenda 2030 y de cara a los objetivos de desarrollo sostenible ⁸ (ver el Apéndice A).

⁸El comercio de derechos de emisión es un instrumento de mercado, mediante el que se crea un incentivo o desincentivo económico que persigue un beneficio medioambiental.

La función objetivo queda como:

$$\begin{aligned}
 F.O = \min \sum_{wpng} & (P_w \cdot DUR_n \cdot CV_g \cdot gp_{wpng} + CSU_g \cdot su_{wpng}) \\
 & + \sum_{wpni} P_w \cdot DUR_n \cdot CENS \cdot ens_{wpni} \\
 & + \sum_{wpng} P_w \cdot CO2_{cost} \cdot ER_g \cdot gp_{wpng} \\
 & + \sum_{ijc} CFT_{ijc} \cdot ict_{ijc}
 \end{aligned} \tag{3.1}$$

3.3.4. Restricciones

Existen dos tipos de restricciones en cualquier modelo: las restricciones obligatorias y las opcionales [10]. Las obligatorias son las relacionadas con el límite operacional de la red en cuanto a generación, transporte de energía y almacenaje. Las opcionales están más relacionados con límites externos a la red como límite de inversión y de contaminación. Estas restricciones tienen como propósito dar una mayor flexibilidad al modelo.

Las restricciones ⁹ se pueden dividir en 5 grupos. A continuación, se presentan las restricciones del modelo openTEPES más relevantes de cara a los casos de estudio desarrollados:

1. Planificación horaria: tres tipos de restricciones.

a) Lógica de la planificación horaria:

$$uc_{wpng} - uc_{wp,n-v,g} = su_{wpng} - sd_{wpng} \quad \forall wpng$$

b) Máxima generación en la rampa a subir [21]:

$$\frac{p_{wpnt} - p_{wp,n-v,t} + ur_{wpnt}}{DUR_n \cdot RU_t} \leq uc_{wpnt} - su_{wpnt} \quad \forall wpnt$$

c) Mínima generación en la rampa a bajar [21]:

$$\frac{p_{wpnt} - p_{wp,n-v,t} - dr_{wpnt}}{DUR_n \cdot RD_t} \geq -uc_{wp,n-v,t} + sd_{wpnt} \quad \forall wpnt$$

2. Reserva: dos tipos de restricciones. Donde a es el área del sistema eléctrico del caso de estudio.

⁹A parte de las enumeradas existen otras que relacionan ambos grupos.

a) A subir:

$$\sum_{g \in a} ur_{wpng} \geq UR_{wpna} \quad \forall wpna$$

b) A bajar:

$$\sum_{g \in a} dr_{wpng} \geq DR_{wpna} \quad \forall wpna$$

3. Balance: un tipo de restricción:

$$\begin{aligned} \sum_{g \in i} gp_{wpng} + ens_{wpni} = & D_{wpni} + \sum_{jc} l_{wpnijk} + \sum_{jc} l_{wpnjic} + \\ & \sum_{jc} l_{wpnijk} + \sum_{jc} f_{wpnijk} - \sum_{jc} f_{wpnjic} \quad \forall wpni \end{aligned}$$

4. Generación: cuatro restricciones [8, 9].

a) Máxima generación del segundo bloque p_{wpng} :

$$\frac{p_{wpng} + ur_{wpng}}{GP_g - \underline{GP}_g} \leq uc_{wpng} \quad \forall wpng$$

b) Mínima generación del segundo bloque p_{wpng} :

$$\frac{p_{wpng} + ur_{wpng}}{GP_g - \underline{GP}_g} \geq 0 \quad \forall wpng$$

c) Tiempo mínimo de subida para una unidad térmica [22]:

$$\sum_{n+v-TU_t} su_{wpnt} \leq uc_{wpnt} \quad \forall wpnt$$

d) Tiempo mínimo de bajada para una unidad térmica [22]:

$$\sum_{n+v-TD_t} sd_{wpnt} \leq 1 - uc_{wpnt} \quad \forall wpnt$$

5. Red o líneas: cinco tipos de restricciones.

a) Capacidad máxima de la línea:

$$-ict_{ijc} \leq \frac{f_{wpnijk}}{F_{ijc}} \leq ict_{ijc} \quad \forall wpnijk, ijc \in Cand. \text{ lines}$$

b) Flujo de cargas DC:

$$\frac{f_{wpnijk}}{F_{ijc}} = (\Theta_{wpni} - \Theta_{wpnj}) \cdot \frac{S_B}{X_{ijc} \cdot F_{ijc}} \quad \forall wpnijk, ijc \in Exist. lines$$

c) Pérdidas óhmicas:

$$-\frac{L_{ijc}}{2} \cdot f_{wpnijk} \leq l_{wpnijk} \leq \frac{L_{ijc}}{2} \cdot f_{wpnijk} \quad \forall wpnijk$$

Las restricciones asociadas a la planificación horaria definen de la forma más compacta y robusta posible la relación entre la inversión, la generación y las variables de arranque despacho y parada sin incurrir en excesivos tiempos de computación.

Las restricciones de reserva definen la relación entre la reserva de cada grupo en cada estado de operación y la demandada total por el sistema.

La restricción de balance es una y se aplica a todos los nodos. Se basa en la primera ley de Kirchhoff y garantiza que la potencia entrante y saliente sean iguales.

En cuanto a la generación se definen aquellas restricciones relacionadas con la capacidad de los grupos, las reservas y las rampas horarias de generación.

Por último, se tienen las restricciones asociadas a las líneas, que tienen que ver con la capacidad de las mismas, las ecuaciones del flujo de cargas, –que se aproxima por DC– y la segunda ley de Kirchhoff. En la relajación del flujo de cargas del modelo se consideran las pérdidas de potencia con el factor de pérdidas establecido en el modelo. Se definen como el flujo por el factor de pérdidas y se modelan como demandas de potencia en los nodos que definen a la línea.

Adicionalmente se ha definido una definición en forma de restricción que permite calcular los costes totales en cada estado de operación. Esto se ha hecho precisamente porque se necesita de cara a la reducción del problema.

$$\begin{aligned} co_{wpn} = & \frac{cf}{wpn_{tot.}} + \sum_{nd} (p_w \cdot DUR_{wpn} \cdot CENS \cdot ens_{wpn,nd}) \\ & + \sum_{n_r} (p_w (DUR_n (CV_{n_r} \cdot pg_{wpn,n_r} + CCV_{n_r} \cdot uc_{wpn,n_r}) + SU_{n_r} \cdot su_{wpn,n_r} + SD_{n_r} \cdot sd_{wpn,n_r})) \\ & + \sum_{n_r} (p_w \cdot CCO2 \cdot ER_{co2,n_r} \cdot pg_{wpn,n_r}) \end{aligned} \quad (3.2)$$

Dicha ecuación queda definida para cada escenario de operación con su probabilidad asignada P_w y en ella se pueden distinguir cuatro términos; cada cual asigna un coste total a cada estado de operación. El primero de ellos distribuye el coste fijo total cf , es decir el de inversión total, a lo largo de todos los estados de operación $wpn_{tot.}$ El segundo

término atribuye un coste de penalización $CENS$ a toda la energía no servida en la red en el estado de operación en cuestión $ens_{wpn,nd}$ durante el tiempo de duración del estado DUR_{wpn} . El tercer término suma para cada estado de operación todos los costes de operación de todos los generadores que nos son renovables n_r : los variables y los fijos. El coste variable es un coste por cada MW producido ($CV_{n_r} \cdot pg_{wpn,n_r}$), por otro lado los costes fijos se dividen en el coste por estar simplemente acoplado $CCV_{n_r} \cdot uc_{wpn,n_r}$, los de arranque $SU_{n_r} \cdot su_{wpn,n_r}$ y los de parada $SD_{n_r} \cdot sd_{wpn,n_r}$. El cuarto y último término asigna una penalización $CCO2$ por todas las emisiones producidas por un generador $ER_{co2,n_r} \cdot pg_{wpn,n_r}$.

3.4. Obtención de las variables de inversión

A continuación, se describen los tres pasos seguidos para la obtención de las variables de inversión en las líneas de refuerzo. El primer paso consiste en la obtención del conjunto de líneas de refuerzo candidatas a construirse. Seguidamente se reduce la dimensión del problema original aplicándose el algoritmo de reducción. Se obtiene así un problema distinto y simplificado que representa la operación del original. Por último, se resuelve este problema y se obtienen las decisiones de inversión finales. Este procedimiento se aplicará a ambos casos de estudio, cuyos resultados se expondrán y analizarán en los capítulos siguientes. En la Figura 3.6 se resumen todos los pasos.

El algoritmo de reducción está en estrecha comunicación con los casos de estudio desarrollados y con el modelo empleado. Este acepta una formulación del modelo y caso de estudio con escenarios de probabilidad, aunque en este proyecto se adopte el enfoque determinista. Se puede visualizar el código de reducción en el repositorio de **github**.

3.4.1. Primer paso

Selección de líneas candidatas

Si bien el proyecto se centra en el algoritmo de reducción de los estados de operación, parte de un conjunto de refuerzos candidatos a la red actual. Así siendo imposible considerar todos los refuerzos posibles en los que invertir se pretende construir un conjunto de candidatos. Para ello lo que se hará es ejecutar el modelo con la red sin refuerzos candidatos aumentando el valor de la demanda un 20 %. Esto se hace para saber cuáles son las líneas que más solicitadas están. La idea de este algoritmo es conocer, por tanto, cuáles son las líneas más usadas, y en función del nivel de utilización proponer o no un refuerzo para esa línea.

Así, con una capacidad de 150 MW aquellas líneas que tengan un porcentaje de uso más del 80 % de media aspiran a tener refuerzos candidatos. Estas son simplemente posibles inversiones a acometerse, que posteriormente el modelo decidirá si acometerlas o no. El uso instantáneo de cada línea se mide como:

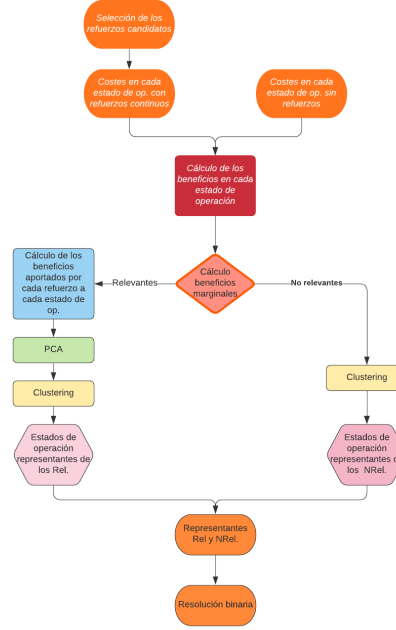


Figura 3.6: Diagrama de la metodología a seguir

$$U_{lin_{i,j,wpn}} = \frac{F_{lin_{i,j,wpn}}}{NC_{lin_{i,j,wpn}}} \quad \forall i, j, wpn$$

Donde $F_{lin_{i,j,wpn}}$ representa el flujo en una línea para cada estado de operación y $NC_{lin_{i,j,wpn}}$ es la capacidad de la misma para dicho estado.

3.4.2. Segundo paso

Se pretende reducir el número de estados de operación para obtener un conjunto reducido de estados representativos. El proceso para conseguir dicha reducción requiere de 3 pasos:

1. Resolución previa para conocer los costes totales del sistema en cada estado de operación de los 4356 sin ningún refuerzo candidato instalado.
2. Estimación de la operación óptima: resolución relajada que implica resolver los 4356 estados de operación iniciales con variables de inversión de los refuerzos continuas para:
 - a) Conocer el conjunto de inversión –continua– óptima en cada refuerzo.
 - b) Conocer los costes totales en cada estado de operación asociados al conjunto del punto anterior.

3. Aplicación del algoritmo de reducción.

La resolución previa proporciona los costes totales de la red en caso de que no se instalen refuerzos. La estimación de la operación proporciona unos costes en cada estado de operación. Estos costes son irreales porque se asocian a una red en la que se instalan refuerzos continuos, lo cual es una asunción falsa, ya que en realidad se instalan o no se instalan. Sin embargo, estos costes se consideran como una estimación de los costes totales óptimos. Es decir que se asume que el conjunto óptimo real de inversiones en la red dará unos costes parecidos a los costes que se obtienen en la resolución relajada. Esto es precisamente lo que se ha referido en la Subsección 2.2.2.

Así, el algoritmo de reducción requiere de conocer el conjunto de inversiones candidatas, los costes totales en la red sin refuerzos y estimar los costes totales óptimos—con variables de inversión relajadas—.

Una vez realizada la resolución previa y la estimación de la operación óptima se aplica el algoritmo de reducción. Este se compone de tres etapas: distinción entre los estado de operación relevantes y no relevantes, procedimiento a los relevantes y procedimiento a los no relevantes.

Algoritmo de reducción

El objetivo es reducir la operación del sistema a los estados de operación representantes para resolver con variables binarias el problema. Los representantes serán estados de operación que, de manera conjunta, representarán al año operacional.

Separación en relevantes y no relevantes

Una vez realizadas la resolución previa y la estimación de la operación se procede a realizar una segmentación entre los estados de operación relevantes y no relevantes. Esta separación se hace por dos razones. En primer lugar, para garantizar una buena representación y en segundo lugar para aumentar la rapidez y eficiencia del algoritmo.

El objetivo es considerar solamente aquellos estados de operación que mejor representen los beneficios obtenidos al desplegar el conjunto óptimo de inversiones continuas sobre los refuerzos. Esto implica sacar representantes de aquellos estados de operación que generan más beneficios y de los que o bien generan pocos beneficios o que incurren en un coste. Si se optimizase solamente con los representantes de los estado de operación más beneficiosos se estarían conduciendo la solución, indefectiblemente, hacia un subóptimo; en definitiva, se estaría sesgando la estimación. Del mismo modo ocurriría si se hiciese con los estado de operación que incurren en menos beneficios. Optimizar la red con estos estados representantes equivale a hacerlo con todos los estados de operación.

Para obtener los representantes se aplicará el algoritmo de clustering por separado; por un lado, al conjunto de los estado de operación relevantes — los que generan más beneficios — y por otro lado a los no relevantes — los que generan menos beneficios o incurren en más costes —. Para mejorar la representación final se separarán los estados de operación en dos grupos: en aquellos relevantes y en los no relevantes.

La agrupación de los estados de operación en relevantes y no relevantes permite aplicar criterios de clusterización distintos y más rápidos y eficientes. Esto permite reducir el tiempo de reducción.

Con todo esto se dividen los estados de operación en el grupo de los relevantes o beneficiosos y en el grupo de los no relevantes o menos beneficiosos. El criterio empleado para separar ambos grupos es el ratio entre el beneficio aportado por el conjunto de refuerzos continuos y el coste de inversión en cada estado de operación. Si dicho ratio es mayor que uno entonces pertenece al grupo de los relevantes, en cambio si es menor pertenece a los no relevantes. Por tanto, se realizará dicha operación en cada estado para luego realizar la separación.

Computación del ratio en cada estado de operación

La diferencia para cada estado de operación entre los costes sin refuerzos y los costes con las inversiones relajadas son los beneficios de dicho estado, que se asume similar a los beneficios de la solución real. Así, por un lado, se tiene CRC_{wpn} que representa los Costes con Refuerzos Continuos definidos en cada estado de operación. En el otro lado están los CSR_{wpn} que representa los Costes Sin Refuerzos, igualmente, en cada estado de operación. No obstante, como el criterio de separación entre relevantes y no relevantes es el ratio entre beneficio y coste de inversión, hay que dividir la resta de dichos costes entre los costes de inversión asociados al estado de operación en cuestión. Los costes de inversión en cada estado de operación son los costes de inversión totales entre el número de estados de operación presentes, es decir $\frac{CF}{wpn_{tot}}$. En la Ecuación 3.3 se puede ver dicha operación.

$$B_{wpn} = \frac{CSR_{wpn} - CRC_{wpn}}{\frac{CF}{wpn_{tot}}} \quad (3.3)$$

Selección de los estados de operación relevantes

Tras el cálculo anterior se agrupan los estados de operación en dos conjuntos: uno de estado de operación relevantes en los que el ratio entre el beneficio y los costes son mayores que uno y otro de estado de operación no relevantes en los que el ratio es menor que uno. Que el ratio en un estado de operación sea menor que uno no significa que la inversión no sea rentable en ese estado de operación, de hecho lo es si dicho ratio es mayor que cero; si es negativo entonces la inversión en dicho estado no es rentable. Aun así, que una inversión en un estado no sea rentable no es determinante; lo que establece qué inversión sea o no rentable es el conjunto de los estados de operación, no uno.

$$\begin{cases} \text{si } B_{wpn} \geq 1 \rightarrow & \text{estado de operación relevante} \\ \text{si } B_{wpn} < 1 \rightarrow & \text{estado de operación no relevante} \end{cases}$$

Procedimiento a los relevantes

Una vez se han separado ambos grupos los estados relevantes y no relevantes son sometidos a procesos estadísticos distintos. A continuación, se verá el proceso únicamente aplicado a los estados de operación relevantes.

Beneficio de cada refuerzo en cada hora de operación

El siguiente paso es computar los beneficios aportados por cada refuerzo continuo a cada estado de operación relevante.

El problema está en cómo calcularlo, ya que los beneficios asociados a cada refuerzo, debido al carácter del problema, dependen unos de otros. De forma que distinguir o medir el beneficio asociado a cada refuerzo es una tarea compleja. Hay dos aproximaciones a este cálculo bien conocidas [23] y que, de algún modo, permiten estimar su valor. Estas estrategias son la estrategia PINT y la estrategia TOOT ¹⁰.

La estrategia PINT consiste en calcular el beneficio aportado por cada refuerzo como la diferencia de costes entre el caso sin refuerzos y el caso con el refuerzo continuo (es decir, con la variable de inversión relajada) a evaluar. Su ecuación es la siguiente:

$$BR_{wpn,ni,nf,c}^{pint} = CSR_{wpn} - ccr_{wpn,ni,nf,c} \quad (3.4)$$

Donde CSR_{wpn} representa el Coste en cada estado de operación Sin Refuerzos y $ccr_{wpn,ni,nf,c}$ el Coste en cada estado Con el Refuerzo correspondiente.

Por otro lado, la estrategia TOOT consiste en calcular el coste asociado a cada refuerzo como la diferencia de costes totales en cada estado de operación entre tener todos los refuerzos continuos menos el evaluado y tener todos los refuerzos. La ecuación es la siguiente:

$$BR_{wpn,ni,nf,c}^{toot} = CCR_{wpn} - ccr_{wpn,ni,nf,c} \quad (3.5)$$

Donde CCR_{wpn} representa los Costes totales Con los refuerzos óptimos continuos y $ccr_{wpn,ni,nf,c}$ el coste sin el Refuerzo evaluado, que es el que va variando dependiendo del refuerzo a considerar.

Como se ha dicho anteriormente, ninguna de estas propuestas es del todo acertada. Esto se debe a que el beneficio de cada refuerzo depende de sí mismo y del resto. Sin embargo, con las estrategias TOOT y PINT se deduce el beneficio de cada refuerzo sin considerar el conjunto entero. Sin resolver este problema, se establece un compromiso definiendo los beneficios como la semisuma de ambas estrategias. De tal forma que queda lo siguiente:

$$BR_{wpn,ni,nf,c} = 0,5 \cdot BR_{wpn,ni,nf,c}^{toot} + 0,5 \cdot BR_{wpn,ni,nf,c}^{pint} \quad (3.6)$$

Esta parte es la que más tiempo consume a nivel computacional, ya que requiere para cada refuerzo de una resolución completa del modelo. La forma de hacerlo es ir fijando sucesivamente dentro de un bucle las variables de inversión a 0 en la estrategia

¹⁰ *ENTSO-E elaborated a cost and benefit analysis methodology (CBA)*. URL: <https://tyndp.entsoe.eu/cba/>

TOOT o a los valores relajados que propone la resolución relajada del problema en la estrategia PINT.

Análisis de componentes principales

Antes de aplicar clustering es conveniente aplicar PCA para reducir las dimensiones del problema. Una vez computados los beneficios aportados por cada refuerzo a cada estado de operación se tiene una matriz en la que las filas representan los estados de operación y las columnas los beneficios asignados a cada refuerzo. Así las filas son las observaciones y las columnas las variables. El objetivo es explicar con el menor número de variables posibles gran parte de la variabilidad de los datos.

El algoritmo empleado lo que hace es rotar los ejes originales para trasladar la covarianza a la varianza, eliminando la correlación entre las variables. Para ello busca el ángulo de rotación que maximice la varianza.

Las componentes principales son el resultado de este algoritmo, cuyas coordenadas se expresan en el sistema original. La primera componente principal es aquella que más varianza explica, la segunda aquella perpendicular a la primera que más varianza explica después de la primera, y así sucesivamente. Se puede ver un ejemplo en la Figura 3.7¹¹. En este caso el algoritmo empleado será el proporcionado por la librería de Python sklearn [24].

Este algoritmo devuelve el sistema anterior en coordenadas de las componentes principales. El nivel de reducción será del 95 %, es decir que se expresarán las observaciones en el espacio de las componentes principales que expliquen más de un 95 % de la varianza total. Las componentes principales serán llamados en adelante refuerzos principales. Estos son una combinación lineal de los refuerzos originales. Dichos refuerzos principales explican la varianza de los beneficios en los estados de operación y permiten conocer cuáles son los refuerzos que más impacto tienen sobre los beneficios, así como las relaciones entre ellos. Cuantos más refuerzos principales haya menor es la correlación que existe entre los beneficios aportados por los refuerzos. Se espera que la variabilidad de la generación renovable se traslade a los beneficios asociados a cada refuerzo, derivando en un mayor número de refuerzos principales. En cambio, sin la presencia de la generación renovable los beneficios en todos los refuerzos estarán altamente correlacionados haciendo necesarios pocos refuerzos principales.

Clustering a los relevantes

Una vez aplicado PCA se aplica clustering, también con [24]. El método de clustering empleado será k-means. K-means es un método de agrupación de observaciones representadas en un espacio dimensional. La clusterización depende por tanto del criterio de medida de distancia entre las observaciones. El algoritmo se basa en un criterio de distancia entre puntos preestablecido y el concepto de inercia o error de cuantización

¹¹Imagen obtenida de Wikipedia, URL: https://es.wikipedia.org/wiki/An%C3%A1lisis_de_componentes_principales




Figura 3.7: Ejemplo de la dirección que siguen las componentes principales




Figura 3.8: Proceso iterativo de k-means clustering

QE .

$$QE = \sum_{i=0}^n \min_{u_j \in C} \|x_i - u_j\|^2 \quad (3.7)$$

El algoritmo coge unos centroides aleatorios lo más alejados entre sí. Asignan las observaciones a cada cluster de forma que se garantice, con el criterio de distancia considerado, el menor error de cuantización posible seguidamente calcula para cada cluster la media de las observaciones y ese es el nuevo centroide; el centroide se ha desplazado un poco respecto del centroide anterior, así que de nuevo se hace el cálculo y se asigna a cada observación el cluster que garantice el menor error. Este proceso se realiza iterativamente hasta que los centroides apenas se desplacen. Este proceso entero se repite varias veces porque dependen de los centroides iniciales asignados aleatoriamente; cada proceso entero se llama réplica, que se controla mediante la semilla. La clusterización final es aquella réplica que resulte en un menor error de cuantización. Se puede observar

un ejemplo de este proceso iterativo en la Figura 3.8 ¹². El número de iteraciones para cada réplica será de 300 y el número total de réplicas es de 10.

El número de clusters adecuado se escoge en el codo del diagrama número de QE frente al número de clusters. En la Figura 3.9 un buen compromiso entre complejidad y error sería 5 clusters.




Figura 3.9: QE frente al número de clusters

En este punto se aplica por tanto dicho algoritmo al grupo de los estados de operación relevantes. Dichos estados de operación, después de aplicar PCA han quedado representados en el espacio de los beneficios de los refuerzos principales. Si por tanto hay tres refuerzos principales, cada estado de operación tendrá tres coordenadas, donde cada una indica el beneficio asignado a dicho estado de operación por un refuerzo principal. El resultado que se busca es tener los estados de operación representantes de cada cluster.

Los centroides del K-means se calculan como el centro de gravedad de todas las observaciones en un cluster y por tanto no son necesariamente observaciones reales. Sin embargo, el objetivo es reducir la operación del año a ciertas horas del mismo, por tanto se necesita realizar una operación adicional: calcular la observación más cercana a cada centroide para luego posteriormente sacar su índice horario.

Procedimiento a los no relevantes

Una vez terminado el proceso a los relevantes se sacan representantes a los no relevantes.

Los estados no relevantes se clusterizan en el espacio unidimensional del ratio entre los beneficios y el coste de inversión. Dicho ratio se ha definido en la Ecuación 3.3.

En este punto se tienen una serie de estados de operación representantes en el grupo de los relevantes y en el de los no relevantes. El siguiente paso es reducir la operación de

¹²Imagen obtenida del foro Stack Overflow, URL: <https://stackoverflow.com/questions/60312401/when-using-the-k-means-clustering-algorithm-is-it-possible-to-have-a-set-of-dat>

la red a esos estados de operación representantes. Como ya se ha explicado, el número de clusters o estados representantes de cada grupo de relevantes y no relevantes depende del codo de la Figura 3.9. No obstante, hay que asignar un peso a cada estado de operación representante. En este caso se le asigna a cada uno el número de horas contenidas en su cluster correspondiente. De tal forma que el número de horas de operación sean las mismas que antes de la reducción.

3.4.3. Tercer paso

Resolución binaria

Una vez reducida la operación se obtiene un problema distinto al original y menos complejo. Con todo esto se pasa de 4356 estados de operación distintos a tantos estados de operación como clusters se hayan contemplado. En tal caso, aunque el número de estados de operación se haya visto reducido, el número de horas totales se mantiene igual. Reduciendo la operación del sistema se reduce el número de ecuaciones para las que se deben cumplir las restricciones establecidas en el modelo de optimización, haciendo posible en pocos segundos una propuesta final de inversiones para el año a planificar.

La función objetivo será los costes totales mínimos. La solución en cuanto a función objetivo y a variables de inversión no será la misma que la solución binaria real por dos motivos. El primero es por el error cometido al estimar los beneficios asociados a cada refuerzo. En segundo lugar, porque se comete un error al resolver las variables de inversión con un problema distinto al original pues el objetivo final del procedimiento de reducción es mantener las decisiones binarias originales.

Una vez reducidos los estados de operación de la red habiendo asignado correctamente el número de horas a cada estado de operación se ha reducido la complejidad en el modelo. Esto implica que se puede ahora, en la resolución binaria aumentar uno o varios niveles de complejidad, en concreto en cuanto a las variables binarias.

Capítulo 4

Presentación y análisis de resultados

En este capítulo se presentan los resultados obtenidos al aplicar los tres pasos descritos en la Sección 3.4 sobre los casos de estudio A y B. Posteriormente se realizará un análisis de éstos.

4.1. Resultados

En esta sección se encuentran los resultados obtenidos en ambos casos para la reducción y la resolución posterior. A continuación, se presenta un resumen de todos ellos:

- PRIMER PASO:
 - Tabla con los refuerzos candidatos.
- SEGUNDO PASO:
 - Número de estados de operación relevantes y no relevantes.
 - Tabla resumen de las inversiones relajadas y funciones objetivo.
 - Para los relevantes:
 - **PCA**: Scree Plot con la varianza explicada por cada refuerzo principal.
 - **Clustering**: Número de clusters vs. Error de Cuantización.
 - **Representación** de los beneficios en el espacio de los refuerzos principales.
 - Para los no relevantes:
 - **Clustering**: Número de clusters vs Error de Cuantización.

- Tiempos de cómputo del algoritmo de reducción.
- Reducción en el número de estados de operación.
- TERCER PASO:
 - Tabla resumen con todas las variables de inversión binarias y relajadas y sus funciones objetivo respectivas.

Antes de presentar los resultados es importante realizar una serie de definiciones previas. El objetivo de la reducción es obtener un problema equivalente al original, más simple y cuyas variables de inversión óptimas sean parecidas –si no iguales– a las del original. Es por esto por lo que a lo largo de esta sección se hablará de dos versiones: la versión relajada y la versión binaria. La versión relajada es el problema original con 4356 estados y con variables de inversión continuas. Por otro lado, cuando se hable de versión binaria se hace referencia al problema simplificado, esto es, con el número de estados de operación reducido y con variables de inversión binarias. A pesar de que ambas versiones vengan del mismo problema son, estrictamente hablando, problemas diferentes.

Por otro lado, en cuanto a los métodos de reducción se hablará del criterio de los beneficios, del nivel de carga y de la demanda neta. El primero es el que se aplica en el Capítulo 3. Por otro lado, se recuerda que mientras el segundo clusteriza en el espacio del nivel de demanda total el tercero lo hace en aquella porción de la demanda que no cubren las renovables.

4.1.1. Primer Paso

Selección de líneas candidatas

Bajo un incremento de la demanda del 20 % las líneas –sin ningún refuerzo instalado– con un uso medio superior al 80 % son, en el caso A y B las siguientes:

Caso B			Caso A		
Nº Total=8			Nº Total=9		
Node_114	Node_116	A23	Node_112	Node_123	A21
Node_212	Node_223	B21	Node_113	Node_123	A22
Node_213	Node_223	B22	Node_114	Node_116	A23
Node_214	Node_216	B23	Node_212	Node_223	B21
Node_221	Node_222	B34	Node_213	Node_223	B22
Node_312	Node_323	C21	Node_214	Node_216	B23
Node_313	Node_323	C22	Node_312	Node_323	C21
Node_314	Node_316	C23	Node_313	Node_323	C22
-	-	-	Node_314	Node_316	C23

Tabla 4.1: Conjunto de líneas candidatas en ambos casos de estudio

4.1.2. Segundo Paso

Resolución de la versión relajada

A continuación se presentan los resultados de la versión relajada de ambos casos:

Sin generación renovable			F.O. Relajada		
			928.62 M€		
			Nº estados de op. 4356		
Línea candidata			Inversión Relajada	F.O. PINT (M€)	F.O. TOOT (M€)
Node_112	Node_123	A21	0.62	993.30	930.05
Node_113	Node_123	A22	0.08	1000.42	928.65
Node_114	Node_116	A23	0.33	996.47	929.25
Node_212	Node_223	B21	0.87	979.36	931.91
Node_213	Node_223	B22	0.96	976.86	933.51
Node_214	Node_216	B23	0.34	990.26	929.60
Node_312	Node_323	C21	0.54	986.18	930.74
Node_313	Node_323	C22	0.79	980.54	934.37
Node_314	Node_316	C23	0.43	988.05	930.75

(a) Caso A

Con generación renovable			F.O. Relajada		
			738.16 M€		
			Nº estados de op. 4356		
Líneas candidatas			Inversión relajada	F.O. PINT (M€)	F.O. TOOT (M€)
Node_114	Node_116	A23	0.00	812.19	812.19
Node_212	Node_223	B21	0.65	793.94	740.80
Node_213	Node_223	B22	0.78	790.51	742.95
Node_214	Node_216	B23	0.51	796.23	740.88
Node_221	Node_222	B34	1.00	794.02	755.51
Node_312	Node_323	C21	0.32	802.94	738.94
Node_313	Node_323	C22	0.66	795.71	742.51
Node_314	Node_316	C23	0.56	797.31	741.72

(b) Caso B

Tabla 4.2: Resultados de la versión relajada

Donde la “F.O. Relajada” es la función objetivo con variables de decisión de inversión continuas y 8712 horas en 4356 estados de operación. “F.O. PINT” y “F.O. TOOT” son las funciones objetivo obtenidas al aplicar las estrategias PINT y TOOT para cada refuerzo continuo evaluado. La columna inversión relajada representa el valor de la decisión de inversión relajada.

Número de estados relevantes y no relevantes

Computada la diferencia en cada estado de operación entre los costes sin refuerzos continuos y con ellos se obtiene con el ratio que el número de estados de operación relevantes y no relevantes es:

	4356 estados de operación	
	Caso A	Caso B
Relevantes	2420	2422
No relevantes	1936	1934

Tabla 4.3: Número de estados de operación relevantes y no relevantes en cada caso

Procedimiento a los estados relevantes

En cada resolución PINT y TOOT se computan los beneficios en cada estado de operación relevante. Así, quedan representados los estados relevantes en el espacio de los beneficios en cada refuerzo. A partir de aquí se aplica PCA y clustering para obtener un conjunto de estados de operación representantes con sus horas de duración asociadas.

Primero se hallará el número de refuerzos principales necesarios en ambos casos. Estos refuerzos, que son las componentes principales, conformarán el espacio en el que quedarán representados en cada caso los estados de operación relevantes para luego iniciar el proceso de clustering. Al final de este apartado se resumen los resultados de clustering para todos los estados de cada caso.

PCA

En la Figura 4.1 se puede ver la varianza explicada por las componentes principales en los estados relevantes de ambos casos. El número de refuerzos principales que explican más del 95 % de la varianza total es de uno en el caso A y dos en el caso B.




Figura 4.1: Tanto por uno de varianza explicada por cada una de las componentes principales

Clustering

El procedimiento de clustering a los relevantes se aplica en el espacio de los beneficios en los refuerzos principales. En la Figura 4.2 se puede ver el error de cuantización frente al número de clusters en ambos casos.

El número de clusters se puede escoger más allá del codo de la curva sin incurrir en un coste elevado de computación, ya que el codo tiene lugar en un número pequeño de clusters.




Figura 4.2: QE frente al número de clusters en los relevantes

Así, el número de clusters y estados de operación representantes en los relevantes será de 10 en el caso A y 25 en el caso B.

Con todo esto, la información recogida de la aplicación del criterio de clustering K-means se resume para ambos casos en la Tabla 4.4 y en la Tabla 4.5. En dichas tablas se presentan:

- “Representantes”: estado de operación representante de cada cluster.
- “Cluster ID”: ID del cluster al que representa cada estado representante.
- “Nº de observaciones”: número de estados de operación contenidos en el cluster correspondiente.

Por último, se tiene la representación de los estados de operación relevantes en el espacio de los beneficios aportados por cada refuerzo principal. Son precisamente esas componentes principales las que explican la varianza representada en la Figura 4.1. Además, los datos están organizados por clusters con los centroides en forma de cruz. En la columna de la izquierda se tienen las representaciones del caso A y a la derecha el caso B. En la Figura 4.3 se puede ver dicha representación para ambos casos.

Representantes			Cluster ID	Nº de muestras
sc01	y2030	16/11/2030 17:00	0	284
sc01	y2030	11/01/2030 17:00	1	73
sc01	y2030	02/05/2030 15:00	2	154
sc01	y2030	27/07/2030 19:00	3	258
sc01	y2030	20/11/2030 13:00	4	215
sc01	y2030	06/03/2030 11:00	5	283
sc01	y2030	01/02/2030 19:00	6	122
sc01	y2030	05/11/2030 15:00	7	102
sc01	y2030	13/02/2030 15:00	8	269
sc01	y2030	08/12/2030 19:00	9	176

(a) Caso A

Representantes			Cluster ID	Nº de muestras
sc01	y2030	01/04/2030 13:00	0	103
sc01	y2030	12/11/2030 15:00	1	71
sc01	y2030	09/02/2030 13:00	2	404
sc01	y2030	17/07/2030 17:00	3	122
sc01	y2030	23/07/2030 9:00	4	97
sc01	y2030	01/07/2030 15:00	5	29
sc01	y2030	23/12/2030 19:00	6	71
sc01	y2030	06/09/2030 19:00	7	88
sc01	y2030	15/01/2030 17:00	8	29
sc01	y2030	20/02/2030 15:00	9	220
sc01	y2030	22/08/2030 19:00	10	106
sc01	y2030	08/01/2030 9:00	11	33
sc01	y2030	27/03/2030 17:00	12	89
sc01	y2030	10/12/2030 19:00	13	19
sc01	y2030	13/03/2030 19:00	14	66
sc01	y2030	13/06/2030 15:00	15	75
sc01	y2030	15/01/2030 7:00	16	138
sc01	y2030	06/05/2030 13:00	17	108
sc01	y2030	02/04/2030 17:00	18	124
sc01	y2030	06/05/2030 17:00	19	104
sc01	y2030	17/10/2030 13:00	20	26
sc01	y2030	30/05/2030 11:00	21	101
sc01	y2030	25/01/2030 7:00	22	50
sc01	y2030	11/12/2030 9:00	23	46
sc01	y2030	12/03/2030 13:00	24	103

(b) Caso B

Tabla 4.4: Representantes en el grupo de los relevantes




Figura 4.3: Estados de operación relevantes en el espacio de los beneficios aportados por los refuerzos principales

Procedimiento a los estados no relevantes

El procedimiento de clustering a los no relevantes se aplica en el espacio del ratio entre beneficios y costes de inversión. En la Figura 4.4 se puede ver el error de cuantización frente al número de clusters en ambos casos.




Figura 4.4: QE frente al número de clusters en los no relevantes

El número de clusters y estados de operación representantes en los no relevantes será de 10 en el caso A y 25 en el caso B.

En la Tabla 4.5 se resumen los resultados de clustering en ambos casos para los no relevantes.

Con todo esto se tiene que la reducción para ambos casos de estudio resulta en:

- Caso A: 20 clusters en total.
 - Relevantes: 10 clusters.
 - No relevantes: 10 clusters.
- Caso B: 50 clusters en total.
 - Relevantes: 25 clusters.
 - No relevantes: 25 clusters.

En la Figura 4.5 se puede observar la distribución en cada hora de los estados de operación, a lo largo de todos los días del año, según el cluster al que pertenecen. En las Tablas 4.4 y 4.5 se puede ver el color asociado a cada cluster, donde las tonalidades rojas corresponden al grupo de los relevantes y las verdes a los no relevantes. Como se puede observar los estados de operación relevantes se concentran en la punta de la demanda, es decir, entre las 07:00 y las 21:00 mientras que los no relevantes se concentran en el valle, es decir en las horas nocturnas. Así mismo, si se observan las horas relevantes a lo largo del año se ve una ligera presencia de zonas amarillas y verdes. Estas zonas corresponden a los fines de semana, donde la actividad decrece.

Representantes			Cluster ID	Nº de muestras
sc01	y2030	11/02/2030 1:00	10	585
sc01	y2030	03/12/2030 1:00	11	85
sc01	y2030	26/01/2030 5:00	12	301
sc01	y2030	12/01/2030 15:00	13	84
sc01	y2030	13/08/2030 7:00	14	87
sc01	y2030	18/09/2030 17:00	15	75
sc01	y2030	10/01/2030 1:00	16	588
sc01	y2030	10/03/2030 3:00	17	116
sc01	y2030	12/05/2030 15:00	18	79
sc01	y2030	15/08/2030 3:00	19	420

(a) Caso A

Representantes			Cluster ID	Nº de muestras
sc01	y2030	06/04/2030 5:00	25	53
sc01	y2030	07/04/2030 21:00	26	46
sc01	y2030	11/10/2030 13:00	27	61
sc01	y2030	18/08/2030 7:00	28	195
sc01	y2030	21/07/2030 21:00	29	77
sc01	y2030	25/01/2030 23:00	30	35
sc01	y2030	14/07/2030 17:00	31	58
sc01	y2030	28/07/2030 9:00	32	159
sc01	y2030	19/09/2030 17:00	33	47
sc01	y2030	12/03/2030 3:00	34	42
sc01	y2030	05/04/2030 23:00	35	79
sc01	y2030	05/06/2030 5:00	36	236
sc01	y2030	16/06/2030 19:00	37	47
sc01	y2030	01/06/2030 5:00	38	99
sc01	y2030	04/09/2030 17:00	39	38
sc01	y2030	17/03/2030 9:00	40	48
sc01	y2030	03/03/2030 5:00	41	35
sc01	y2030	11/09/2030 7:00	42	45
sc01	y2030	14/04/2030 23:00	43	90
sc01	y2030	30/08/2030 23:00	44	69
sc01	y2030	27/09/2030 13:00	45	62
sc01	y2030	23/09/2030 23:00	46	43
sc01	y2030	09/03/2030 3:00	47	35
sc01	y2030	03/07/2030 23:00	48	41
sc01	y2030	13/01/2030 7:00	49	194

(b) Caso B

Tabla 4.5: Representantes en el grupo de los no relevantes




Figura 4.5: Densidad de la clusterización en los 363 días

Nivel de reducción

El nivel de reducción de ambos casos se puede observar en la Tabla 4.6. En ella se ve la reducción en el número de ecuaciones y variables en la versión binaria respecto del problema original. La tolerancia en la resolución binaria es de un 0.005. Se ha conseguido resolver en tiempos menores de 3 segundos un problema que a priori es irresoluble. Todo esto, teniendo en cuenta los recursos de computación referenciados en el Apéndice B.

	Problema Original	Versión Binaria
Nº de ecuaciones	2520387	10532
Nº de variables	2715690	11394
Tiempo de computación (s)	-	1

(a) Caso A

	Problema Original	Versión Binaria
Nº de ecuaciones	2434837	27116
Nº de variables	2578243	28804
Tiempo de computación (s)	-	3

(b) Caso B

Tabla 4.6: Comparación del nivel de reducción en funciones objetivo, ecuaciones, variables y tiempo

Por otro lado se tienen los tiempos asociados al algoritmo de reducción que se resumen en la Tabla 4.7. Como se puede ver la mayoría del tiempo se consume en computar los

beneficios PINT y TOOT.

	Caso A	Caso B
Nº de líneas cand.	9	8
Nº de clusters	20	50
PINT (s)	6161	4475
TOOT (s)	7372	5156
PCA y Clustering (s)	12	20
Tiempo total (s)	13545	9651

Tabla 4.7: Tiempos de cómputo en segundos del algoritmo de reducción desarrollado

4.1.3. Tercer Paso

Sin generación renovable			F.O. Relajada	F.O. Binaria	F.O. Problema original
			928.62 M€	912.94 M€	932.00 M€
			Nº estados de op. 4356	Nº estados de op. 20	Nº estados de op. 4356
Línea candidata			Inversión Relajada	Inversión Binaria	Inversión Binaria
Node_112	Node_123	A21	0.62	1	1
Node_113	Node_123	A22	0.08	0	0
Node_114	Node_116	A23	0.33	0	0
Node_212	Node_223	B21	0.87	1	1
Node_213	Node_223	B22	0.96	1	1
Node_214	Node_216	B23	0.34	1	1
Node_312	Node_323	C21	0.54	1	1
Node_313	Node_323	C22	0.79	1	1
Node_314	Node_316	C23	0.43	0	0

(a) Caso A

Con generación renovable			F.O. Relajada	F.O. Binaria	F.O. Problema original
			738.16 M€	728.69 M€	740.70 M€
			Nº estados de op. 4356	Nº estados de op. 50	Nº estados de op. 4356
Líneas candidatas			Inversión relajada	Inversión binaria	Inversión Binaria
Node_114	Node_116	A23	0.00	0	0
Node_212	Node_223	B21	0.65	0	0
Node_213	Node_223	B22	0.78	1	1
Node_214	Node_216	B23	0.51	1	1
Node_221	Node_222	B34	1.00	1	1
Node_312	Node_323	C21	0.32	1	1
Node_313	Node_323	C22	0.66	0	0
Node_314	Node_316	C23	0.56	1	1

(b) Caso B

Tabla 4.8: Resumen de los resultados de inversión

Una vez obtenidos los representantes en cada caso de estudio y el número de muestras que representan se obtiene un problema distinto del original y más simple. Este problema se ha denominado versión binaria. Resolviéndolo se obtienen las variables de

inversión binarias del problema original. Dichas variables de inversión se pueden fijar en el problema original obteniéndose la función objetivo de éste. En la Tabla 4.8 se resume dicha información contrastada con la asociada a la versión relajada, donde “F.O. Binaria” es la función objetivo de la versión binaria y “F.O. Problema original” la función objetivo del problema original.

Si se comparan las funciones objetivo en el problema original y en la versión binaria de la Tabla 4.8 se obtiene una diferencia respecto de la función objetivo del problema original del 2 % en el caso A y del 1.62 % en el caso B.

Aplicando el conjunto de inversiones binarias obtenidas en la versión binaria al problema original se obtienen los siguientes beneficios:

Nº estados de operación: 4356			
	F.O. sin refuerzos (M€)	F.O inversión Binaria (M€)	Beneficio (M€)
Caso A	1001.94	932.00	69.94
Caso B	812.19	740.70	71.49

Tabla 4.9: Beneficios asociados a las variables de inversión binarias

Así, el conjunto de decisiones binarias arrojan un beneficio de 71.49 M€ en el caso B y 69.94 M€ en el caso A.

La versión binaria, a pesar de ser un problema distinto del original debe ser representativo de éste, para que también lo sean sus resultados. Se ha asumido que la versión relajada representa fielmente a la operación óptima del original. Por ello en la solución de ambas versiones la distribución de la generación y de los costes debe ser similar.

En las Figuras 4.6 y 4.7 se pueden ver la energía producida por cada grupo en el problema original con las variables de inversión binarias y en la versión binaria. Las unidades que no aparezcan tienen una generación asignada de cero.




Figura 4.6: Energía generada en *GWh* en el caso A por tecnologías




Figura 4.7: Energía generada en GWh en el caso B por tecnologías

Por otro lado se puede ver en la Tabla 4.12 que la distribución de los costes totales entre ambas versiones se parecen mucho, lo cual demuestra la alta calidad de la reducción.

4.2. Análisis de los resultados

Se ha reducido el problema de 4356 estados de operación a 20 en el caso A y 50 en el B manteniendo la similitud en la distribución de los costes y la generación. Si se aplican el conjunto de decisiones binarias de inversión de las líneas al problema original los resultados obtenidos son excelentes. Si en el caso A la solución relajada es 928 M€, la obtenida al fijar las decisiones binarias en el problema original es de 932 M€. La diferencia es menor de un 0.5 % lo cual demuestra la calidad de la reducción. Lo mismo ocurre con el caso B; la función objetivo relajada es de 738 M€ y la solución binaria en el problema original 740.7 M€: menos de un 0.3 %.

Con todo esto se ha pasado exitosamente de un caso irresoluble con variables binarias a la obtención de una solución binaria muy cercana a la relajada.

En esta sección se realiza un análisis de los resultados. En concreto se analizará:

- Comportamiento y relación existente entre los distintos refuerzos.
- Efecto de las estrategias TOOT y PINT sobre los resultados obtenidos en la aplicación del algoritmo.
- Impacto del algoritmo de reducción en base a beneficios en casos de estudio sin generación renovable.

- Efecto de la generación renovable y el impacto del algoritmo en casos de estudio con recursos renovables.

4.2.1. Comportamiento de los refuerzos

Como se puede ver en la Figura 4.1b el número de componentes principales necesarias para explicar la variabilidad de los estados de operación en el caso B es de dos. Ahora bien, resultaría interesante analizar qué grupos de los refuerzos a proponer están altamente relacionados en sus beneficios. Tal y como se puede observar en la Figura 4.8 existen tres grupos de refuerzos en el caso B cuyos beneficios están altamente correlacionados. Mientras los refuerzos B34 y A23 tienen un comportamiento independiente del resto de refuerzos, el B21, B22, B23, C21, C22 y C23 están altamente correlacionados.


En cuanto al caso A, los resultados se resumen en la Figura 4.9. En este caso se puede ver que existen menos componentes principales que explican toda la variabilidad y que los beneficios de los refuerzos se comportan de manera más correlacionada.

Hay dos características a analizar en el comportamiento de los refuerzos en cada caso de estudio. En primer lugar el número de componentes principales y en segundo lugar los grupos de comportamiento.

En el caso A hay pocas componentes principales, lo cual demuestra que todos los refuerzos están altamente correlacionados entre sí. No obstante, siendo esta correlación entre todos muy alta, es también uniforme, es decir que no se pueden distinguir con claridad subgrupos de comportamiento. Esto significa que todos los refuerzos están correlacionados con el resto prácticamente al mismo nivel. Esto se puede ver en la Figura 4.9a y numéricamente en la Tabla 4.10a. Sin embargo, en el caso B, se puede ver que la introducción de energías renovables no sólo hace que la correlación global sea menor haciendo necesario un mayor número de refuerzos principales sino que no hay uniformidad de correlación, esto es, que se distinguen con mayor claridad subgrupos de comportamiento. Por ejemplo si se observa la Tabla 4.10b se puede ver que efectivamente existe un grupo de correlación entre las B's y las C's que es bastante débil con el A23 y el B34.

En el caso B gran parte de la variabilidad en los beneficios se concentra en el grupo dos mientras que en el caso A, como se ha dicho, está uniformemente distribuida.

Por tanto, se puede concluir que cuando se introducen energías renovables en el sistema la correlación en el comportamiento entre los beneficios de los refuerzos se rompe dando lugar a pequeños subgrupos de relación. La variabilidad introducida por las fuentes renovables “fractura” el sistema en grupos de comportamiento. Este comportamiento no puede ser considerado en la agrupación de criterios generalistas como el criterio de la demanda neta o el criterio del nivel de carga ya que cada estado de operación se ve caracterizado por una única variable. El criterio de los beneficios, sin embargo, caracteriza cada estado de operación en función del número de variables necesarias que permita distinguir dichos grupos de comportamiento. Resulta así en una mejor represen-




(a) Biplot

Refuerzo candidato	Variable	Grupo
A23	1	1
B21	2	2
B22	3	
B23	4	
C21	6	
C22	7	
C23	8	
B34	5	3

(b) Leyenda

Figura 4.8: Grupos de correlación en las variables del caso B



(a) Biplot

Refuerzo candidato	Variable	Grupo
A21	1	1
B21	4	
A22	2	2
C22	8	
A23	3	3
B22	5	
B23	6	4
C21	7	5
C23	9	6

(b) Leyenda

Figura 4.9: Grupos de correlación en las variables del caso A

	A21	A22	A23	B21	B22	B23	C21	C22	C23		A23	B21	B22	B23	B34	C21	C22	C23
A21	1.00	0.93	0.98	0.96	0.97	0.89	0.93	0.96	0.92	A23	1.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
A22	0.93	1.00	0.97	0.92	0.93	0.78	0.84	0.92	0.80	B21	0.00	1.00	0.99	1.00	0.34	0.95	0.97	0.97
A23	0.98	0.97	1.00	0.95	0.96	0.85	0.89	0.95	0.86	B22	0.00	0.99	1.00	0.98	0.37	0.93	0.98	0.98
B21	0.96	0.92	0.95	1.00	0.99	0.88	0.98	0.97	0.95	B23	0.00	1.00	0.98	1.00	0.32	0.96	0.95	0.96
B22	0.97	0.93	0.96	0.99	1.00	0.84	0.96	0.99	0.92	B34	0.00	0.34	0.37	0.32	1.00	0.25	0.38	0.36
B23	0.89	0.78	0.85	0.88	0.84	1.00	0.90	0.77	0.95	C21	0.00	0.95	0.93	0.96	0.25	1.00	0.92	0.95
C21	0.93	0.84	0.89	0.98	0.96	0.90	1.00	0.93	0.98	C22	0.00	0.97	0.98	0.95	0.38	0.92	1.00	0.99
C22	0.96	0.92	0.95	0.97	0.99	0.77	0.93	1.00	0.87	C23	0.00	0.97	0.98	0.96	0.36	0.95	0.99	1.00
C23	0.92	0.80	0.86	0.95	0.92	0.95	0.98	0.87	1.00									

(a) Caso A


(b) Caso B

Tabla 4.10: Matrices de correlación entre los refuerzos

tación. Esta resolución es necesaria cuando se introducen energías renovables que rompe el comportamiento entre los refuerzos, creando subgrupos. No lo es, en cambio, cuando no hay renovables, ya que el comportamiento es común en todos y se puede agrupar en características globales como la demanda neta o total. Esto se verá en la Subsección 4.2.3.

4.2.2. Efecto de las estrategias TOOT, PINT

Como se ha comentado en el Subpárrafo 3.4.2 la estrategia TOOT consiste en asociar a cada refuerzo los beneficios entre tener todos los refuerzos instalados y tener todos menos la evaluada. Del mismo modo se tiene que la estrategia PINT asocia los beneficios poniendo el refuerzo en primer lugar. Como se puede observar en la Figura 4.10 los beneficios asociados a cada refuerzo en cada estado de operación son distintos en ambas estrategias. Esto se debe a que el beneficio asociado a cada refuerzo depende del resto.



(a) Caso A

(b) Caso B

Figura 4.10: Beneficio en M€ aportado por cada refuerzo en cada estado de operación según TOOT y PINT

De hecho, se puede observar que el impacto en los beneficios es mayor cuando el refuerzo evaluado se instala en último lugar. El beneficio TOOT de cada refuerzo es mayor que el PINT en el caso B en el 87 % de los estados de operación y en el A en el 99 %. Es decir, los beneficios son mayores para una misma línea si se pone en último lugar.

Debido a que los beneficios aportados por cada línea dependen del orden en el que van siendo instaladas y a que no todas se construyen en primer o último lugar, un compromiso entre ambas estrategias es la mejor propuesta de cara a asociar beneficios. Como se puede observar la semisuma de ambos beneficios es una estimación sin sesgo.

No obstante, no deja de ser una aproximación. Es precisamente esta aproximación la principal fuente de error del presente algoritmo y que por tanto es necesario evaluar siempre que se vaya a aplicar y enfrentar a otros algoritmos de reducción. De esto se hablará en la Subsección 4.2.4.

El otro error presente en el algoritmo procede de la misma reducción. Este error se comete al simplificar el problema original a un número reducido de estados de operación. Se estima así el conjunto de decisiones de inversión buscado por el obtenido en el problema simplificado. Además, la representación se hace de la versión relajada y no del problema original. Esto acarrea también un error.

4.2.3. Caso A sin generación renovable


En un caso sin renovables, como en el A, los beneficios en los refuerzos principales tienen menos dispersión y variabilidad. Existe, así, una relación casi directa entre los beneficios de los refuerzos. Esto se puede sostener observando la Figura 4.1a. Hay un refuerzo principal, combinación lineal del resto de refuerzos, que explica más del 95 % de la variabilidad de los beneficios. Es precisamente debido a esta escasa variabilidad por lo que anteriormente a la introducción de las energías renovables los métodos de reducción por el nivel de carga eran válidos.

Si se aplica el mismo proceso de reducción a la demanda, clusterizando según el nivel de carga, se obtienen los resultados de la Figura 4.11, donde el gráfico de sedimentación se parece mucho al obtenido en la 4.1a. En cuanto a las decisiones de inversión éstas son exactamente iguales a las obtenidas con el criterio de los beneficios exceptuando el refuerzo B23. Para evaluar el conjunto de decisiones de inversión de cada método se fijan dichas decisiones en el problema original y se mira la función objetivo. Así, se tiene que:

- Método de reducción con el criterio del nivel de carga: 930 M€.
- Método de reducción con el criterio de los beneficios: 932 M€.

A pesar de que los resultados del método de reducción por beneficios son excelentes no son mejores que los obtenidos con el método de reducción con el nivel de carga. Esto se debe a que la no presencia de energías renovables hace que los costes totales dependan directamente del nivel de carga; donde optimizar el modelo con los estados de operación más y menos costosos equivale a hacerlo con los mayores y menores niveles de carga. En este punto, probablemente el método de los beneficios sea peor en casos de estudio sin

renovables debido a la estimación del beneficio asociado a cada refuerzo con la semisuma del PINT y TOOT que en realidad es una aproximación, junto con el error que trae la propia reducción. Por tanto, es de concluir que para reducir el problema en casos de estudio sin renovables es mejor emplear los métodos ex-ante, con los que se ahorra tiempo y se gana precisión.



(a) PCA al nivel de carga

(b) Comparación de los resultados en las inversiones entre el criterio de los beneficios y de nivel de carga con el mismo nivel de reducción: 20 estados de operación

Figura 4.11: Resultados de reducción con el nivel de carga

Si se observa la Figura 4.11b y los resultados obtenidos en la versión relajada en la 4.8a se puede ver que la función objetivo en la versión relajada son 928 M€ y que en la versión binaria, habiendo reducido con el criterio del nivel de carga, es 929 M€. Ambas funciones objetivos se parecen mucho, mientras que la versión binaria al aplicar la reducción con los beneficios es de 912 M€, bastante más lejos de 928 M€. Esto se debe a que el método ex-ante de demanda encuentra representantes de la demanda total o nivel de carga. En casos sin presencia renovable la dependencia de los costes de operación con el nivel de demanda es absoluto, por ello encontrar representantes de la demanda equivale a encontrar representantes de los costes de operación y por tanto conduce a una función objetivo prácticamente igual. Sin embargo, en presencia de renovables esta relación ya no es tan directa: los costes de operación no dependen linealmente de la demanda neta.

Con todo esto, como ya se ha explicado, este método cada vez es menos válido debido a la participación de las renovables. Cada vez es más irreal un sistema sin tecnología renovable.

4.2.4. Caso B con generación renovable

El caso B presenta un 11 % de generación renovable instalada que el caso A no tiene. A continuación se analizan las implicaciones de esto.

El primer efecto se puede ver en la Tabla 4.1. La no integración de los perfiles de generación renovable puede conducir a no seleccionar adecuadamente las líneas candidatas. En el caso A las líneas A21 y A22 se presentan saturadas, mientras que la B34 no;

todo lo contrario al caso B. Esto se debe a que ignorar recursos de generación con una representación del 11 % puede obligar a considerar refuerzos de líneas cuyo uso no está tan solicitado con la presencia de aquella generación ignorada.

En segundo lugar y tal y como se puede ver en la Figura 4.3 la generación renovable afecta considerablemente a la variabilidad de los costes totales. Esto se debe a que entra a cubrir la demanda antes que el resto de las tecnologías, trasladando así su intermitencia. Esto afecta como se ha dicho a la dispersión de los costes y como se puede ver en la Subsección 4.2.1 al comportamiento de los beneficios en los refuerzos. Además el número de clusters necesarios es mayor en el caso con renovables –caso B– que en el caso sin –caso A–, tal y como se puede ver en los codos de las Figuras 4.2 y 4.4.

Un análisis interesante es comparar el método de reducción en base a los beneficios por las líneas con el método ex-ante de la demanda neta para posteriormente comparar el conjunto de decisiones finales, así como las funciones objetivo. En la Tabla 4.11 se resumen los resultados de dicha comparación.

			F.O. Binaria	F.O. Binaria
			724.47 M€	728.47 M€
			Criterio Demanda neta	Criterio de los Beneficios
Líneas candidatas			Inversión Binaria	Inversión Binaria
Node_114	Node_116	A23	0	0
Node_212	Node_223	B21	0	0
Node_213	Node_223	B22	1	1
Node_214	Node_216	B23	1	1
Node_221	Node_222	B34	1	1
Node_312	Node_323	C21	0	1
Node_313	Node_323	C22	1	0
Node_314	Node_316	C23	1	1
			F.O inversión Binaria/4356	F.O inversión Binaria/4356
			740.5 M€	740.7 M€

Tabla 4.11: Comparación de los resultados en las inversiones entre el criterio de los beneficios y de la demanda neta con el mismo nivel de reducción: 50 estados de operación

Como se puede ver el método de los beneficios arroja unos resultados ligeramente peores que el método de la demanda neta. El conjunto de decisiones es similar y ambos resultados son excelentes. El método de la demanda neta es un método ex-ante que no requiere de una resolución previa a la reducción y por tanto supone un ahorro de tiempo de computación frente a los métodos ex-post. La aplicación de uno u otro método depende enteramente del caso de estudio al que se le quiera aplicar la reducción. El criterio de reducción de los beneficios comete un error al estimar los beneficios de cada refuerzo y al reducir la operación. El de la demanda neta comete el mismo tipo de error al reducir la operación y, además, comete otro error al ignorar los flujos de energía renovable. Este último error se debe a restar al perfil de la demanda los perfiles renovables. Precisamente en redes con mucha generación renovable y muy distribuida este último algoritmo comete más error haciendo más recomendable el de los beneficios, algo que cada vez ocurre con más frecuencia. Además, como se ha visto, con la incursión de las renovables se hace más necesario abandonar criterios de reducción generalistas como el de la demanda neta, hacia

otros métodos, como el de los beneficios, que caractericen con una mayor resolución los costes del sistema.

4.3. Estudio económico

Si bien este proyecto es un proyecto de estudio está íntimamente relacionado con el dinero. Como ya se ha dicho, la finalidad de este proyecto es proporcionar viabilidad económica a la operación de la red. No obstante, el objetivo de este estudio es hacer una propuesta de inversión para reducir los costes totales. La propuesta, en este caso, solo alcanza a la construcción de líneas y refuerzos cuyas características técnicas se plantean sucintamente en el caso de estudio. Por ello el objetivo no es planificar una instalación, sino saber dónde deben hacerse.

Con todo esto, en esta sección se presentará la propuesta económica que ofrece el proyecto.

4.3.1. Inversiones y gastos

La inversión se refiere a las nuevas líneas de refuerzo para ambos casos de estudio detallados en el Capítulo 3.

En cuanto a los gastos o costes hay que distinguir entre los de operación y los de inversión. En la Figura 4.12 se puede ver una clasificación de los costes presentes en la planificación, en los que se distinguen los costes de inversión y los costes de operación.




Figura 4.12: Clasificación de los costes presentes en la planificación de ambos casos de estudio

La tasa de carga fija anual de las inversiones realizadas es del 7.5%, por tanto, hay que analizar la viabilidad económica del proyecto durante trece años. Para ello se supondrá que los costes de operación y de inversión serán siempre los mismos a lo largo de los trece años.

Los costes de inversión total y de operación se añaden a continuación:

	C. de operación (M€)	C. de inversión (M€)	C. de emisión (M€)	C. totales (M€)
Versión Relajada	877.27	37.22	14.11	928.60
Criterio Beneficios	873.68	45.00	14.15	932.83
Criterio Demanda neta	878.82	37.50	14.13	930.45
Versión sin refuerzos	987.93	0.00	13.99	1001.92

(a) Caso A

	C. de operación (M€)	C. de inversión (M€)	C. de emisión (M€)	C. totales (M€)
Versión Relajada	693.43	33.57	11.17	738.17
Criterio Beneficios	692.02	37.50	11.19	740.71
Criterio Demanda neta	691.80	37.50	11.19	740.49
Versión sin refuerzos	798.23	0.00	11.45	809.68

(b) Caso B

Tabla 4.12: Costes de operación emisión e inversión

Donde los costes se han analizado para cada propuesta de inversión en los 4356 estados de operación iniciales.

No se desglosarán los costes de inversión en costes de inmovilizado, directos, indirectos, etc. porque no le compete a este estudio trazar económicamente la instalación y construcción de líneas.

4.3.2. Proyección del dinero

A continuación se proyectarán los beneficios generados por la propuesta a lo largo de los trece años siguientes. Como la planificación está hecha para dentro de diez años se tienen esos mismos años para implantar las inversiones propuestas. Por tanto se van a analizar los beneficios ocasionados durante trece años a partir del décimo año desde el tiempo presente.

Se analizará la viabilidad de acometer las inversiones propuestas por el método de reducción de beneficios por las líneas frente a no acometerlo en ambos casos de estudio. A continuación se calcula el valor actual en el primer año de operación de todos los ingresos o ahorros de coste que supondría acometer el proyecto.

Para ambos casos se tiene que:

$$k = \frac{1+r}{1+i}$$

$$VA = V_0 \cdot \frac{k \cdot (1 - k^n)}{1 - k}$$

Donde r es la tasa real del producto e i la tasa de descuento. En este caso no hay tasa real por no representar dicho ingreso un coste en capital. La tasa de descuento será de un 7.4%. Se tiene por tanto que para $n = 13$ años y $k = 0,931$:

- Caso A: $V_0 = 69,09M€ \rightarrow VA = 573,156M€$
- Caso B: $V_0 = 68,968M€ \rightarrow VA = 572,144M€$

4.3.3. Amortización

Cada refuerzo candidato tiene un valor de 100 M€. La propuesta final es invertir en 5 refuerzos en el caso B y en 6 refuerzos en el caso A. Se ha considerado que la vida del proyecto será de 13 años. Con una tasa de descuento i del 7.4 %, se tiene que la amortización de la inversión se calcula como:

$$A = INV \cdot \frac{i \cdot (1 + i)^n}{(1 + i)^n - 1}$$

donde INV en el caso A es 600 M€ y en el caso B 500 M€. Con todo esto se tiene que la amortización de la inversión es:

- Caso A: 72.3 M€
- Caso B: 60.2505 M€

4.3.4. Coste normalizado de la generación

A continuación se obtienen los costes normalizados de generación en el caso de acometer la inversión propuesta por el criterio de los beneficios frente a no invertir en la red. Así se tiene que el coste normalizado de generación se calcula como:

$$LCOE = CT \cdot \frac{i \cdot (1 + i)^n}{(1 + i)^n - 1}$$

Donde El Levelized Cost of Electricity (LCOE) representa el coste anual neto de cubrir la demanda y CT los Costes Totales en toda la vida del proyecto. Para ello se supondrá que los costes totales serán los mismos todos los años. El propósito es por tanto conocer el coste anual de cubrir la demanda acometiendo o no el conjunto de inversiones arrojadas por el criterio de los beneficios, teniendo en cuenta que dentro de los costes totales se encuentra la amortización de la inversión (en caso de invertir). El LCOE es por tanto, teniendo en cuenta los CT de la Tabla 4.12, el siguiente: ¹.

- Caso A
 - criterio de los beneficios: $CT = 12434,6M€ \rightarrow LCOE = 1498,39M€ \rightarrow 89,3134€/MWh$
 - Sin refuerzos: $CT = 13355,6M€ \rightarrow LCOE = 1609,36M€ \rightarrow 95,92€/MWh$
- Caso B
 - criterio de los beneficios: $CT = 9873,69M€ \rightarrow LCOE = 1189,79M€ \rightarrow 70,92€/MWh$

¹Se consideran los CT del criterio beneficios los asociados a fijar sus variables de inversión en los 4356 estados de operación iniciales

- Sin refuerzos: $CT = 10793,2M\text{€} \rightarrow LCOE = 1300,59M\text{€} \rightarrow 77,52\text{€/MWh}$

Como se puede ver la aplicación del algoritmo de reducción supone un ahorro considerable en la producción.

Capítulo 5

Conclusiones

5.1. Conclusiones metodología

La metodología del proyecto se puede resumir en los siguientes puntos:

1. Comprensión general del problema.
 - a) Comprensión general del TEP ¹.
 - b) Comprensión general de la propuesta [17].
 - c) Estudio de la literatura.
 - d) Comprensión del modelo.
2. Aprendizaje de Python.
3. Desarrollo de los dos casos de estudio.
4. Desarrollo del algoritmo.

Para llegar a la parte de desarrollo es necesario previamente haber estudiado y conocido las características del problema general, es decir del TEP y de todas las partes que lo componen: caso de estudio, modelo, algoritmo de selección y algoritmo de reducción. Una vez comprendido el proceso general se estudia con más detalles algunas de sus partes, como por ejemplo el modelo, la planificación horaria, algunas propuestas de los algoritmos, etc. Este proceso se ha realizado principalmente a través de la literatura recomendada por el director. Es recomendable acudir a las revistas citadas en el Apéndice B así como a los estudios citados en la Bibliografía.

Una vez comprendido el problema y sus partes es necesario estudiar a fondo el modelo, ya que el desarrollo del algoritmo se adaptará al modelo. El modelo está compuesto por más de 20 restricciones todas cuidadosamente desarrolladas y detalladas, con lo

¹A. Ramos, E. Alvarez y S. Lumbreras. *Open Generation and Transmission Operation and Expansion planning Model with RES and EES*

cual es necesario un conocimiento preciso de ellas. Conocer el modelo implica aprender Python. Conocer y acudir a los foros mencionados en el Apéndice B es altamente recomendable. Sobre todo, es necesario conocer las librerías de Pandas y Pyomo –cuyo link accesible está en el Anexo mencionado–. El conocimiento de estas y otras herramientas como GIT, son necesarias para poder desarrollar un código eficiente.

Tras todo esto viene el comienzo del desarrollo, que se divide en el desarrollo del caso de estudio y el desarrollo de los algoritmos. El desarrollo del caso de estudio requiere de conocer previamente el modelo, y todas sus estructuras de tablas de datos y diccionarios. El desarrollo del caso de estudio se basa en información aportada en este caso por el IEEE pero implica en gran parte la modificación original del mismo, ya sea porque conviene de cara a lo que se estudia o bien porque esa información no se encuentra.

Por último, viene el desarrollo de los algoritmos como conclusión del aprendizaje conceptual del problema y técnico de Python. Es fundamental en este punto el correcto empleo de la tecnología y sobre todo el uso de repositorios como Github y el uso de sistemas de control de versiones como GIT. Como el desarrollo del algoritmo se hace para dos casos de estudio, es necesario manejar con soltura el uso de ramas en GIT así como la actualización de las versiones. También es fundamental disponer de un ordenador con al menos 8 GB de RAM y más de 2 núcleos. De otra forma se ralentiza mucho el proceso.

5.2. Conclusiones sobre resultados

El objetivo del estudio era aplicar una metodología concreta: la reducción de los estados de operación en función de los beneficios por los refuerzos. Para ello se han planteado otros subobjetivos: el desarrollo de dos casos de estudio con y sin generación renovable y el desarrollo del algoritmo de reducción planteado. Todos estos objetivos se han cumplido satisfactoriamente, consiguiendo pasar de 4356 estados de operación a 20 en el caso A y 50 en el B, manteniendo los costes totales de operación, así como la generación de las tecnologías. No obstante, la aplicación de este algoritmo ha conducido a la obtención de unas conclusiones adicionales que se pueden resumir a continuación en:

1. Método de selección de líneas de refuerzo candidatas.
2. Comportamiento de los refuerzos con y sin generación renovable.
3. Comparativa del algoritmo de reducción en función de los beneficios con el de nivel de carga.
4. Comparativa del algoritmo con el de demanda neta.
5. Nivel de reducción.

Como se puede claramente observar en la 4.8b y en la 4.8a algunas de las líneas que se presentaban saturadas en el método de selección de refuerzos candidatos, en la versión

relajada tienen valores próximos a 0. Esto se debe a que el algoritmo de selección ha ignorado la relación entre los refuerzos candidatos y cómo la necesidad de algunos se ve resuelta con la propuesta de otros. Este comportamiento entre los refuerzos sugiere que conocer la relación entre ellos es un aspecto de suma relevancia cuando hay que formar el conjunto de candidatos. Por otro lado, se observa cómo el algoritmo de reducción propone como inversión algunos de los refuerzos que están próximos a cero como el C21 en el caso B y no propone otros que si están próximos a uno como el B21 en el mismo caso.

Se ha visto en la Subsección 4.2.1 que la generación renovable rompe el conjunto de refuerzos en grupos más pequeños de comportamiento, cosa que no ocurre en escenarios sin generación renovable, en el que el comportamiento de los refuerzos es muy uniforme. Esto puede hacer en algunos casos que el empleo de criterios de reducción generales como el nivel de carga total no sean suficientes; hace necesario el empleo de criterios que atiendan a las características individuales de los refuerzos como lo hace el criterio de los beneficios por las líneas, en el que cada refuerzo queda caracterizado por un beneficio en cada estado de operación. Si bien esta novedad –la de la introducción de energía renovable– hace urgente la valoración de nuevos criterios de reducción, sigue siendo necesario una evaluación del error que estos criterios puedan traer consigo y compararlo con los criterios generales.

Se ha visto en la Subsección 4.2.2 que la tarea de caracterizar cada refuerzo no es algo fácil precisamente porque, en este caso, el beneficio aportado por cada refuerzo depende del resto haciendo imposible su distinción. A pesar de que hay formas de estimarlo con estrategias como la de PINT y la de TOOT esto acarrea un error que puede impactar sobre el óptimo. Se ha visto que en escenarios sin generación renovable el método de reducción en función del nivel de carga, visto el comportamiento de los refuerzos en la Figura 4.9a y los resultados de la Figura 4.11b, es más apropiado que el de los beneficios por las líneas. Sin embargo, en escenarios de generación renovable el criterio de los beneficios ha de ser contrastado con el de la carga neta, el cual también tiene un error asociado al ignorar los flujos renovables de la red. Es por esto por lo que se ha visto que ambos métodos emiten resultados muy similares, siendo mejor el de los beneficios a media que la participación renovable aumenta.

Además, todo algoritmo de reducción comete un error al estimar la operación óptima, así como el conjunto de inversiones óptimas con un problema simplificado y distinto del que se quiere resolver. El criterio de los beneficios asume que la solución óptima del problema original es parecida a la de la versión relajada y emplea así la solución de ésta última para obtener un problema más simple cuya solución se estima como la solución del original. Por tanto, a parte del error común a todos los algoritmos de reducción, el criterio de los beneficios puede cometer más o menos error en la reducción dependiendo de la cercanía de la solución relajada a la original.

Por último, el nivel de reducción del método es excelente: consigue reducir el cálculo a unos segundos. No obstante hay que invertir un tiempo parecido al descrito en la Tabla 4.7.

5.3. Recomendaciones para futuros estudios

Este proyecto puede ser continuado en diferentes aspectos, los cuales se enumeran a continuación:

1. Mayor elaboración en el caso de estudio y en el método de selección de líneas:
 - a) Caso de estudio probabilístico o estocástico.
 - b) Implantación de algoritmos más sofisticados de selección de líneas candidatas.
 - c) Extender el algoritmo de reducción al GEP.
2. Reducción y estimación del error cometido por el criterio de los beneficios.

Como ya se ha dicho, la planificación de la expansión de la red requiere de un caso de estudio, de un conjunto de inversiones candidatas a acometer, de un modelo y, eventualmente, de un algoritmo de reducción.

Teniendo en cuenta que de los elementos anteriormente mencionados se han desarrollado todos menos el modelo, una posible continuación del proyecto sería aumentar el nivel de detalle de los casos de estudio, del algoritmo de selección de líneas candidatas y del algoritmo de reducción de los estados de operación. Todas estas partes se encuentran engarzadas secuencialmente de forma que los resultados arrojados por cada una ellas dependen de la anterior. Aumentar la calidad de los algoritmos y del caso de estudio conducirían a una mayor calidad en la propuesta final para la planificación de la expansión de la red. El método de selección de líneas candidatas es un algoritmo muy rudimentario que necesitaría de una mayor complejidad.

Como se ha dicho el caso de estudio desarrollado es un modelo determinista, en el que se ha contemplado un único escenario con probabilidad 1. Con la participación de las energías renovables los modelos han tenido que migrar del determinismo a los estudios de probabilidad e incertidumbre. Sería, por tanto, muy conveniente realizar un estudio para sacar las funciones de densidad de probabilidad de la generación renovable, en concreto de la eólica y la solar. Ya que la forma más conveniente de integrar esta generación es, según la literatura, mediante escenarios de probabilidad, sería muy interesante desarrollar dos casos de estudio con alta presencia de generación renovable y estudiar el impacto de su diseño en la toma de decisiones final. Esto podría hacerse entrenando el diseño mediante simulación para sacar los perfiles más representativos y posteriormente simular la toma de decisiones de inversión en el año a planificar.

Otra vía de desarrollo sería cualificar la planificación con un algoritmo de selección de refuerzos candidatos adecuado. En el proyecto se ha seguido la vía de la saturación de las líneas, no obstante, éste no considera la influencia mutua de los refuerzos, haciendo quizás innecesarios algunos de los refuerzos que se presentaban saturados. Es decir, considerar en la selección de refuerzos candidatos el impacto del resto de candidatos estableciendo relaciones entre las propuestas de inversión de forma que se pueda ver qué inversiones son redundantes propuestas otras.

Por último, el algoritmo de reducción está desarrollado para el TEP y para casos de estudio con varios escenarios de probabilidad, aunque en realidad solo se haya usado uno. Ya que el modelo está habilitado para la TEP y para el GEP y el algoritmo de selección de candidatos, así como el caso de estudio pueden desarrollarse para incorporar también el GEP, sería interesante adaptar el algoritmo de reducción contemplando de manera conjunta los beneficios de cada refuerzo y de cada generador candidato, permitiendo así una propuesta más completa de cara a la planificación.

Se ha visto que el empleo del criterio de los beneficios depende del tipo de caso de estudio: si hay o no participación renovable y, en caso de que la haya cuánta. Por lo que una vía de estudio interesante sería estimar o calcular el error que comete el criterio de los beneficios al realizar la estimación óptima con el problema simplificado. De tal forma que se pudiesen tabular los errores y analizarlos comparativamente con otros métodos para ver en qué casos de estudio aplicar dicho algoritmo. Es decir, tratar de medir el error asociado al algoritmo. En esta dirección, analizando las fuentes del error sería también interesante tratar de reducirlo, sobre todo en cuanto al error cometido en la estimación de los beneficios. Sería interesante ver si hay alguna estrategia más allá del PINT y TOOT que permita distinguir el beneficio aportado por cada refuerzo.

Apéndice A

Anexo I: Desarrollo sostenible

Los Objetivos de Desarrollo Sostenible (ODS) surgen en 2015 cuando en una cumbre en la ONU se pactó entre 193 países una serie de objetivos y metas para garantizar el desarrollo sostenible y cumplir con la agenda 2030.

Los ODS pretenden abordar y solucionar grandes problemas presentes y de un gran impacto social. Entre ellos se pueden distinguir la lucha contra la desigualdad, el hambre y la pobreza, garantizar unas condiciones básicas de educación y trabajo y el freno del cambio climático, entre otros. Cada objetivo que conforma un ODS está a su vez formado por una serie de *targets* o subobjetivos con sus indicadores correspondientes.

El objetivo de este anexo es presentar una serie de objetivos primarios y secundarios con los que se alinee este proyecto, así como aportar información de los indicadores.

A.1. Alineación con los objetivos ODS

Objetivo primario

El principal objetivo de entre los 17 que presenta Naciones Unidas con el que se relaciona este proyecto es el objetivo 7: *“Afordable and clean energy”*.

Según la Asociación de Empresas de Energía renovables (APPA) la participación de las energías renovables en la cobertura de la demanda fue de un 15.5 % en 2018. Mientras las energías contaminantes como el carbón y el petróleo bajan cada año, lo hacen a ritmos del 0.5 % y manteniendo su hegemonía. A pesar de que las renovables crecen al 7 % es necesario un mayor impulso. La única forma de que la participación de la renovable aumente es que el operador lo permita; y solo puede llegar a confiar en su carácter ingestionable si existe una buena praxis en la planificación.

Según la base de datos de Energía Sostenible Para Todos (SE4ALL) el 89.6 % de la población tiene acceso a la electricidad. Esto supone en una población de 7625 millones de habitantes que 793 millones de personas no tienen acceso a la electricidad. Por tanto, la planificación y la expansión de la red todavía es urgente.

Este proyecto propone un método de reducción que permite la expansión de la red al mínimo coste y considerando la participación de las energías renovables. Los ahorros en los costes de operación de la red se reducen en muchos casos en millones de euros con la aplicación de este algoritmo, lo cual permite una electrificación más ambiciosa y además de acuerdo con las nuevas exigencias de descarbonización. Como se puede observar en los resultados arrojados por la Figura 2.3 el ahorro comparativo de este método con otros métodos es muy grande, haciendo esencial si no fundamental su consideración a la hora de planificar. La planificación es un ejercicio que un buen operador no puede saltarse cuando se trata de ampliar el alcance de la red y la cobertura de la demanda. De los costes que se acumulen en la operación depende el ritmo al que va creciendo la red y por tanto, en países subdesarrollados la provisión de un medio básico para el desarrollo integral. Siendo muy interesante cual es el impacto de este método sobre la electrificación, esta relación no es posible debido a la novedad del algoritmo desarrollado. Sin embargo, observando los resultados se puede ver que los ahorros se miden en millones de euros. Este ahorro en los costes permite el crecimiento en la electrificación.

Objetivo secundario

Un objetivo secundario con el que se relaciona este proyecto es el objetivo 9: “*Industry, innovation and infrastructure*”. Este proyecto proporciona un medio para tomar decisiones de cara a invertir en infraestructura; una infraestructura sostenible económicamente. El objetivo del algoritmo es minimizar costes y tomar decisiones de inversión que sean necesarias de cara a la sostenibilidad económica de la red. Uno de los aspectos que trata este objetivo es el “uso eficiente de los recursos” y el desarrollo de “infraestructuras fiables, sostenibles, resilientes y de calidad”, que es precisamente a lo que contribuye este estudio. En concreto se relaciona con las metas 9.1, 9.4 y 9.5.

A.2. Cuantificación

- Indicador 7.2.1 El porcentaje de consumo en este caso de energía renovable es de un 21.8 % en el caso B con un ahorro de 69 millones de euros según la propuesta de inversiones binarias arrojadas por el modelo.
- Indicador 7.1.1: Dado un presupuesto constante en la operación de la red, los beneficios permitirían, con un coste medio de 1000€ de instalación eléctrica por habitante, el acceso a la electricidad de 69000 habitantes cada año durante 10 años.
- Indicador 7.B.1: inversión en la expansión de la red generando los beneficios anteriores y permitiendo la provisión de energía moderna y renovable.
 1. 45 M € en el caso A invertidos en la expansión de la infraestructura.
 2. 37.5 M € en el caso B invertidos en infraestructura.

- 9.4.1: planificación de la expansión de la red reduciendo las emisiones asociándolas un peaje por el coste medioambiental.
- 9.5.1: el proyecto anima y establece nuevas líneas de investigación para reducir más eficientemente la operación de la red e incrementar el nivel de satisfacción de los objetivos anteriores.

Apéndice B

Anexo II: Recursos empleados

B.1. Recursos de cómputo

B.1.1. Características del ordenador

- Ordenador: HP Pavilion x360 Convertible 14-dh1xxx.
- Memoria RAM: 16 GB.
- Número de CPUs: 4.

B.2. Aplicaciones

B.2.1. Python

- IDE: Pycharm.
- Python: 3.7.6 Miniconda3.
- Librerías ¹:
 - Numpy 1.18.1: funciones matemáticas.
 - Pandas 1.0.1: lectura y escritura de datos.
 - Scikit-learn 0.22.2: aplicación de clustering y PCA.
 - Matplotlib 3.1.3.: representación gráfica en 3-D, 2-D, scatter plots, diagrama de líneas.
 - Seaborn 0.10.1: Representación gráfica bar plots e histogramas y representación estadística.

¹Pinchando en las librería se puede acceder a las páginas web oficiales de cada librería

- Pyomo 5.6.8: Modelo de optimización: Función objetivo, restricciones, sets, parámetros y resolución.
- Gurobipy 9.0.2: solucionador empleado en la resolución. Licencia de uso académico.

B.2.2. GIT

- Sistema de control de versiones GIT.
- Github: repositorio para código desarrollado con dos ramas: una para cada versión del caso de estudio.
 1. Caso A: 25 versiones.
 2. Caso B: 24 versiones.
 - Red diseñada: *CSV* con los diccionarios y tablas de datos correspondientes a los señalados en el Capítulo 3.
 - Beneficios.py: código de reducción de los estados de operación originalmente desarrollado.

B.2.3. Revistas científicas

- Science Direct: documentación muy variada sobre TEP y GEP. Acceso a contenido de pago gracias a suscripciones académicas.
- IEEE.
- ElServier Energy: revista de energía.

B.2.4. Otros

- ESIOS: obtención de datos de generación:
 - Generación medida hidráulica en el 2019 en A coruña, Álava, Badajoz, Cádiz, Cantabria, Castellón, Girona, Huesca, Lleida, Lugo, Navarra, Palencia, Pontevedra, Salamanca, Segovia, Tarragona, Toledo y Vizcaya.
 - Generación medida eólica en España en el 2019.
 - Generación medida solar en España en el 2019.
- Stack-OverFlow: foro de Python.
- Geeks for Geeks: web de Python.
- Overleaf: $\text{\LaTeX}$.

- Infogram: tablas.
- LucidChart: esquemas y diagramas explicativos.

B.2.5. Latex

- $\text{\LaTeX}$: herramienta de edición de textos. Toda la redacción está diseñada con esta herramienta.

Bibliografía

- [1] D. Z. Fitiwi, F. de Cuadra, L. Olmos y M. Rivier. “A new approach of clustering operational states for power network expansion planning problems dealing with RES (renewable energy source) generation operational variability and uncertainty”. En: *Energy* 90 (2015), págs. 1360-1376. ISSN: 0360-5442. DOI: <https://doi.org/10.1016/j.energy.2015.06.078>. URL: <http://www.sciencedirect.com/science/article/pii/S0360544215008348>.
- [2] P. Vilaça Gomes, J. T. Saraiva, L. Carvalho, B. Dias y L. W. Oliveira. “Impact of decision-making models in Transmission Expansion Planning considering large shares of renewable energy sources”. En: *Electric Power Systems Research* 174 (2019), págs. 105852. ISSN: 0378-7796. DOI: <https://doi.org/10.1016/j.epsr.2019.04.030>. URL: <http://www.sciencedirect.com/science/article/pii/S0378779619301658>.
- [3] E. B. Cedeño y S. Arora. “Performance comparison of Transmission Network Expansion Planning under deterministic and uncertain conditions”. En: *International Journal of Electrical Power & Energy Systems* 33.7 (2011), págs. 1288-1295. ISSN: 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2011.05.005>. URL: <http://www.sciencedirect.com/science/article/pii/S0142061511001001>.
- [4] M. Moeini-Aghaie, A. Abbaspour y M. Fotuhi-Firuzabad. “Incorporating Large-Scale Distant Wind Farms in Probabilistic Transmission Expansion Planning-Part II: Case Studies”. En: *IEEE Transactions on Power Systems* 27 (2012), págs. 1594-1601. ISSN: 1558-0679. DOI: [10.1109/TPWRS.2011.2182364](https://doi.org/10.1109/TPWRS.2011.2182364). URL: <https://ieeexplore.ieee.org/document/6151863>.
- [5] P. Seljom y A. Tomasgard. “Short-term uncertainty in long-term energy system models — A case study of wind power in Denmark”. En: *Energy Economics* 49 (2015), págs. 157-167. ISSN: 0140-9883. DOI: <https://doi.org/10.1016/j.eneco.2015.02.004>. URL: <http://www.sciencedirect.com/science/article/pii/S0140988315000419>.

- [6] X. Zhang y A. J. Conejo. “Robust Transmission Expansion Planning Representing Long- and Short-Term Uncertainty”. En: *IEEE Transactions on Power Systems* 33.2 (2018), págs. 1329-1338. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2017.2717944. URL: <https://ieeexplore.ieee.org/document/7954668>.
- [7] M. Nicolosi. “The Importance of High Temporal Resolution in Modeling Renewable Energy Penetration Scenarios”. En: *Lawrence Berkeley National Laboratory* (2010). URL: <https://escholarship.org/uc/item/9rh9v9t4>.
- [8] D. A. Tejada-Arango, S. Lumbreras, P. Sanchez-Martin y A. Ramos. “Which Unit-Commitment Formulation is Best? A Systematic Comparison”. En: *IEEE Transactions on Power Systems* 35.4 (2019), págs. 2926-2936. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2019.2962024. URL: <https://ieeexplore.ieee.org/document/8941313>.
- [9] G. Morales-España, J. M. Latorre y A. Ramos. “Tight and Compact MILP Formulation for the Thermal Unit Commitment Problem”. En: *IEEE Transactions on Power Systems* 28.4 (2013), págs. 4897-4908. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2013.2251373. URL: <https://ieeexplore.ieee.org/document/6485014>.
- [10] R. Hemmati, R. Hooshmand y A. Khodabakhshian. “State-of-the-art of transmission expansion planning: Comprehensive review”. En: *Renewable and Sustainable Energy Reviews* 23 (2013), págs. 312-319. ISSN: 1364-0321. DOI: <https://doi.org/10.1016/j.rser.2013.03.015>. URL: <http://www.sciencedirect.com/science/article/pii/S1364032113001743>.
- [11] X. Zhang y A. J. Conejo. “Candidate line selection for transmission expansion planning considering long- and short-term uncertainty”. En: *International Journal of Electrical Power & Energy Systems* 100 (2018), págs. 320-330. ISSN: 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2018.02.024>. URL: <http://www.sciencedirect.com/science/article/pii/S0142061517329836>.
- [12] S. Lumbreras, A. Ramos y P. Sánchez. “Automatic selection of candidate investments for Transmission Expansion Planning”. En: *International Journal of Electrical Power & Energy Systems* 59 (2014), págs. 130-140. ISSN: 0142-0615. DOI: <https://doi.org/10.1016/j.ijepes.2014.02.016>. URL: <http://www.sciencedirect.com/science/article/pii/S0142061514000799>.
- [13] G. Blanford y V. Niemeyer. “Examining the role of renewable resources in a regional electricity model for the US”. En: *30th international energy workshop*. 2011.

-
- [14] F. Jimenez y M. D. Webster. “Optimal Selection of Sample Weeks for Approximating the Net Load in Generation Planning Problems”. En: ESD Working Paper Series. 2013. URL: <http://hdl.handle.net/1721.1/102959>.
- [15] P. Nahmmacher, E. Schmid, L. Hirth y B. Knopf. “Carpe diem: A novel approach to select representative days for long-term power system modeling”. En: *Energy* 112 (2016), págs. 430-442. ISSN: 0360-5442. DOI: <https://doi.org/10.1016/j.energy.2016.06.081>. URL: <http://www.sciencedirect.com/science/article/pii/S0360544216308556>.
- [16] J. M. Morales, S. Pineda, A. J. Conejo y M. Carrion. “Scenario Reduction for Futures Market Trading in Electricity Markets”. En: *IEEE Transactions on Power Systems* 24.2 (2009), págs. 878-888. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2009.2016072. URL: <https://ieeexplore.ieee.org/document/4801580>.
- [17] Q. Ploussard, L. Olmos y A. Ramos. “An Operational State Aggregation Technique for Transmission Expansion Planning Based on Line Benefits”. En: *IEEE Transactions on Power Systems* 32.4 (2017), págs. 2744-2755. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2016.2614368. URL: <https://ieeexplore.ieee.org/document/7582509>.
- [18] M. Boiteux. *La Tarification des demandes en pointe: application de la théorie de la vente au coût marginal*. place Henri-Bergson, 1949. URL: <https://books.google.es/books?id=dxEazQEACAAJ>.
- [19] J. Choi, T. D. Mount y R. J. Thomas. “Transmission Expansion Planning Using Contingency Criteria”. En: *IEEE Transactions on Power Systems* 22.4 (2007), págs. 2249-2261. ISSN: 1558-0679. DOI: 10.1109/TPWRS.2007.908478. URL: <https://ieeexplore.ieee.org/document/4349068>.
- [20] C. Grigg y col. “The IEEE Reliability Test System-1996. A report prepared by the Reliability Test System Task Force of the Application of Probability Methods Subcommittee”. En: *IEEE Transactions on Power Systems* 14.3 (1999), págs. 1010-1020. ISSN: 1558-0679. DOI: 10.1109/59.780914. URL: <https://ieeexplore.ieee.org/document/780914>.
- [21] P. Damcı-Kurt, S. Küçükyavuz, D. Rajan y A. Atamtürk. “A polyhedral study of production ramping”. En: *Mathematical Programming* 158 (2016), págs. 175-205. ISSN: 1436-4646. DOI: 10.1007/s10107-015-0919-9. URL: <https://doi.org/10.1007/s10107-015-0919-9>.
- [22] D. Rajan, S. Takriti y col. “Minimum up/down polytopes of the unit commitment problem with start-up costs”. En: *IBM Research Report* 23628 (2005), págs. 1-14. URL: <https://www.semanticscholar.org/paper/IBM->

- Research-Report-Minimum-Up%2FDown-Polytopes-of-Rajan-Takriti/
b88642e36b414d5929fed48593d0ac46ae3e2070#references.
- [23] F. Báñez Chicharro, L. Olmos Camacho, A. Ramos Galán y J. M. Latorre Canteli. “A benefit-based methodology to rank transmission expansion projects”. En: *Respositorio de Comillas* (2016). URL: <http://hdl.handle.net/11531/14236>.
- [24] F. Pedregosa y col. “Scikit-learn: Machine Learning in Python”. En: *Journal of Machine Learning Research* 12 (2011), págs. 2825-2830. URL: <https://scikit-learn.org/stable/>.