

# Renovables y baterías: un romance del siglo XXI

Salvador Pineda

Departamento de Ingeniería Eléctrica

Universidad de Málaga

*ORCID: 0000-0002-1089-0970*

*spineda@uma.es*

Juan Miguel Morales

Departamento de Matemática Aplicada

Universidad de Málaga

*ORCID: 0000-0002-9114-686X*

*juan.morales@uma.es*

## Resumen

La expansión del sistema eléctrico requiere la selección de una cartera óptima de tecnologías de generación de energía y de líneas de transporte que satisfagan las necesidades de suministro eléctrico a largo plazo y minimicen los costes de inversión y operación. Los problemas de expansión son difíciles de resolver ya que tienen que considerar las distintas condiciones de operación del sistema eléctrico durante los próximos 10 o 20 años. Como la demanda eléctrica es relativamente fácil de predecir en función de la estación del año, el día de la semana, y la hora del día, el principal parámetro que afectaba los planes de expansión del siglo XX era el crecimiento anual de la demanda eléctrica. Sin embargo, la integración de energías renovables y sistemas de almacenamiento de energía durante el siglo XXI presenta un desafío importante en la planificación de la expansión del sistema eléctrico debido a la variabilidad y la incertidumbre asociadas con estas tecnologías. En este artículo presentamos una metodología basada en *clusterización* cronológica para resolver la planificación óptima de la expansión del sistema eléctrico considerando la integración efectiva de las energías renovables y los sistemas de almacenamiento de energía.

**Palabras clave:** Agregación de períodos de tiempo, problema de expansión, clustering, almacenamiento de energía, energías renovables.

**MSC Subject classifications:** 90B50, 90C06, 90C59.

## 1. Introducción

Un sistema eléctrico es un conjunto de instalaciones y equipos que permiten generar y transportar energía eléctrica desde los lugares donde se produce hasta los lugares donde se consume. Los componentes principales de un sistema eléctrico son los generadores, las líneas de transporte y la demanda. Los generadores son máquinas que transforman diferentes tipos de energía en energía eléctrica. Por lo general, se utilizan combustibles fósiles, como el petróleo, el gas natural y el carbón, así como fuentes de energía renovable, como la energía eólica, solar e hidráulica. Las líneas de transporte son las estructuras que transportan la energía eléctrica desde los generadores hasta los lugares donde se consume. Estas líneas pueden ser muy largas y extensas, y están diseñadas para transportar grandes cantidades de energía a largas distancias con la menor pérdida posible. La demanda es la cantidad de energía eléctrica que se utiliza en un momento dado. Esta demanda puede variar ampliamente a lo largo del día y a lo largo del año, dependiendo de factores como la hora del día, la época del año, las condiciones climáticas y la actividad económica. Por lo tanto, los sistemas eléctricos deben estar diseñados para adaptarse a estas variaciones y satisfacer las necesidades de energía de la sociedad en todo momento.

Los sistemas eléctricos son fundamentales para la sociedad porque prácticamente todas las actividades modernas requieren energía eléctrica. Desde la iluminación y los electrodomésticos en los hogares, hasta la maquinaria y los equipos en la industria, la electricidad es esencial para una amplia variedad de aplicaciones. Además, muchos sistemas críticos, como los sistemas de comunicaciones y los sistemas de transporte público, dependen en gran medida del suministro de energía eléctrica confiable. La falta de electricidad puede tener graves consecuencias en la sociedad, desde interrupciones en la producción y las comunicaciones, hasta la pérdida de vidas en situaciones de emergencia médica.

Por lo tanto, debido a que la mayoría de las actividades económicas dependen de su correcto funcionamiento, los sistemas eléctricos se consideran infraestructuras críticas. Por otro lado, desde el punto de vista de la ingeniería, los sistemas eléctricos son extremadamente complejos ya que deben cumplir con una serie de requisitos técnicos y de seguridad. El hecho de que sean sistemas críticos para el funcionamiento de la sociedad, a la vez que complejos desde el punto de vista ingenieril, hace imprescindible la creación de modelos matemáticos que permitan un análisis exhaustivo de los sistemas eléctricos.

El problema de planificación de un sistema eléctrico implica tomar decisiones complejas y estratégicas sobre cómo diseñar, construir y operar el sistema eléctrico para satisfacer la demanda de energía eléctrica de manera confiable y rentable. El problema de planificación del sistema eléctrico se puede dividir en dos componentes principales: la planificación de la generación y la planificación de la red de transporte. La planificación de la generación implica tomar decisiones sobre qué tipos de generadores se deben utilizar y cómo se deben despachar para satisfacer la demanda de energía. La planificación de la red de transporte se enfoca en la construcción y operación de las líneas de transporte que conectan los generadores con los consumidores finales.

Resolver el problema de planificación de un sistema eléctrico es un desafío complejo que implica considerar múltiples variables y restricciones, así como encontrar soluciones óptimas que satisfagan múltiples objetivos y metas. Algunos de los desafíos más importantes que deben abordarse en la planificación del sistema eléctrico son los siguientes:

- Variabilidad de la demanda: la demanda de energía eléctrica varía en función de múltiples factores, incluyendo el clima, la hora del día y la actividad económica. Esto hace que sea difícil prever con precisión cuánta energía se necesitará en el futuro.

- Incertidumbre en los recursos energéticos: los recursos energéticos, como el viento, la luz solar y el agua, pueden ser variables e impredecibles. La disponibilidad de estos recursos puede afectar la capacidad de los generadores para producir energía eléctrica y, por lo tanto, puede afectar la capacidad de satisfacer la demanda.
- Restricciones técnicas: la operación de un sistema eléctrico está sujeta a múltiples restricciones técnicas, incluyendo la capacidad de las líneas de transporte y los transformadores, la estabilidad y la seguridad del sistema.
- Regulaciones y objetivos ambientales: los sistemas eléctricos están sujetos a múltiples regulaciones y objetivos ambientales, que pueden incluir límites de emisiones de gases de efecto invernadero, normas de calidad del aire y objetivos de energía renovable.

En resumen, el problema de planificación de un sistema eléctrico es un desafío complejo que requiere una consideración cuidadosa de múltiples factores. Además, la solución de este problema es crucial para garantizar un suministro de energía eléctrica confiable y sostenible para las personas, las empresas y las comunidades. En este artículo presentamos una metodología basada en clusterización cronológica para resolver la planificación óptima de la expansión del sistema eléctrico considerando la integración efectiva de las energías renovables y los sistemas de almacenamiento de energía.

## 2. Revisión bibliográfica

La expansión de la capacidad de generación y transporte de un sistema eléctrico es un problema de planificación a largo plazo que abarca varios años (Hemmati, Hooshmand y Khodabakhshian, 2013) y que debe tener en cuenta los requisitos y limitaciones de la operación a corto plazo. Dado que una representación horaria de todo el horizonte de planificación haría que el modelo de expansión de capacidad sea computacionalmente intratable, la mayoría de los modelos de planificación de energía consideran una representación temporal estilizada (Frew y Jacobson, 2016; Poncelet, Delarue et al., 2016). Probablemente, el enfoque más simple consiste en caracterizar los parámetros dependientes del tiempo, como la demanda de electricidad, utilizando curvas de duración que se aproximan mediante una cantidad limitada de bloques (Murphy y Smeers, 2005; Roh, Shahidehpour y Wu, 2009). A pesar de su eficiencia computacional, esta representación temporal no tiene en cuenta la cronología de los parámetros variables y, por lo tanto, no permite la inclusión de restricciones intertemporales (por ejemplo, límites de rampa de generación) en el modelo de expansión de capacidad.

Una representación temporal más sofisticada y ampliamente utilizada se basa en la selección de un conjunto reducido de días o semanas representativas del horizonte de planificación (Merrick, 2016). A diferencia de las curvas de duración, se preserva la cronología de los parámetros variables, al menos dentro de cada día o semana representativa, por lo que se pueden considerar algunas restricciones intertemporales, como los límites de rampa. Para ilustrar este enfoque, la Figura 1 representa la demanda agregada de electricidad en Dinamarca durante las primeras dos semanas de 2010 (línea sólida) y la aproximación utilizando solo dos días representativos (línea discontinua). Una vez que se eligen los dos días representativos, los datos vinculados a cada día se reemplazan por aquellos correspondientes a su día representativo más cercano. Debido al fuerte patrón diario de la demanda de electricidad, este enfoque resulta relativamente preciso.

Los días o semanas representativos se han utilizado en varios modelos de expansión de capacidad de generación y transporte. Los autores de (Koltsaklis y Georgiadis, 2015) determinan las adiciones

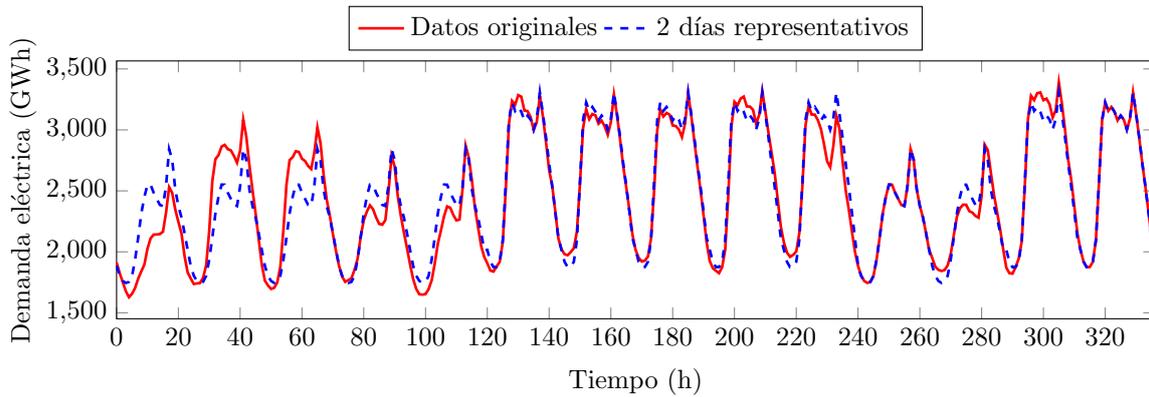


Fig. 1: Aproximación de la demanda eléctrica usando dos días representativos

óptimas de capacidad utilizando un día representativo para cada mes del horizonte de planificación. La referencia (Munoz y A. D. Mills, 2015) emplea un modelo de planificación de inversión en generación para evaluar la contribución de la generación solar a la adecuación de recursos mediante días de muestra. Los autores de (Dvorkin et al., 2017) proponen un modelo binivel para decidir el tamaño y la ubicación óptimos de los dispositivos de almacenamiento utilizando días representativos. El valor del almacenamiento de energía se estima en (Sisternes, Jenkins y Botterud, 2016) utilizando semanas representativas.

En la mayoría de los modelos de expansión de capacidad, los días o semanas representativos se eligen utilizando técnicas de agrupamiento clásicas como K-means o agrupamiento jerárquico (Hastie, Tibshirani y Friedman, 2009; ElNozahy, Salama y Seethapathy, 2013). Nuevos métodos para seleccionar días representativos en problemas de expansión de capacidad se han propuesto recientemente en la literatura técnica. Por ejemplo, el artículo (Poncelet, Hoschle et al., 2017) proporciona un enfoque novedoso basado en la optimización para seleccionar períodos representativos. Del mismo modo, los autores de (Liu, Sioshansi y Conejo, 2017) proponen un procedimiento de agrupamiento jerárquico modificado para elegir un conjunto reducido de días representativos que conserva importantes características estadísticas de los datos de entrada, como la correlación.

Sin embargo, los sistemas eléctricos actuales están experimentando importantes cambios que pueden socavar la validez de los enfoques actuales para tener en cuenta las condiciones de operación a corto plazo en problemas de planificación a largo plazo, a saber, la gran penetración de la generación de energía renovable y la creciente integración de tecnologías de almacenamiento.

La generación eléctrica de origen renovable tiene varias ventajas. En primer lugar, son fuentes de energía limpia y abundante que ayudan a mitigar el cambio climático y reducir las emisiones de gases de efecto invernadero. Además, los costes de generación han disminuido, y las energías renovables ofrecen diversidad y disponibilidad a nivel mundial. Sin embargo, también existen desafíos, como la intermitencia de la generación renovable y la necesidad de infraestructura adicional, así como posibles impactos ambientales y limitaciones geográficas. Por otro lado, a diferencia de la demanda de electricidad, la producción eléctrica de origen renovable, por ejemplo, no muestra un patrón diario fuerte. De hecho, no es raro observar 2-3 días de fuertes vientos seguidos de 2-3 días de bajos vientos (Sisternes, Jenkins y Botterud, 2016). Obviamente, este comportamiento dinámico no puede

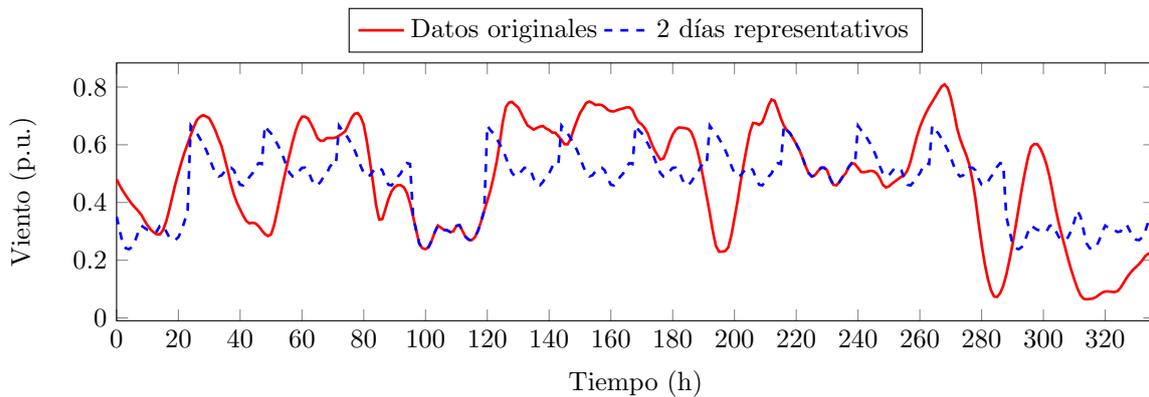


Fig. 2: Aproximación de la producción de energía eólica usando dos días representativos

ser capturado adecuadamente por días representativos, como se ilustra en la Figura 2. Esta figura muestra el factor de capacidad de la producción de energía eólica agregada en Dinamarca durante las primeras dos semanas de 2010 (línea sólida). Puede observarse la mala aproximación lograda si se consideran dos días representativos (línea discontinua).

En paralelo con el crecimiento de la generación de energía renovable fluctuante, el papel cada vez más importante del almacenamiento de energía en los sistemas eléctricos también cuestiona el uso de días representativos en los modelos de expansión de capacidad (Beaudin et al., 2010; Wogrin y Gayme, 2015; Pandzic et al., 2015). En este artículo vamos a diferenciar entre tecnologías de almacenamiento de energía *intradía* e *interdía*.

El almacenamiento de energía *intradía* se refiere a la capacidad de almacenar energía durante períodos más cortos, como horas o incluso minutos, dentro de un mismo día. Este tipo de almacenamiento es útil para equilibrar la oferta y la demanda de energía en tiempo real, especialmente en sistemas con fuentes de energía intermitentes, como la energía solar o eólica. Por ejemplo, si hay un exceso de energía generada en un momento determinado, se puede almacenar para su uso posterior cuando la demanda sea mayor o cuando las fuentes de generación no estén produciendo suficiente energía.

Por otro lado, el almacenamiento de energía *interdía* se refiere a la capacidad de almacenar energía durante períodos más largos, como días o incluso semanas. Este tipo de almacenamiento es útil para abordar la variabilidad estacional de la generación de energía renovable y la variación en la demanda de energía a lo largo del tiempo. Permite acumular energía durante períodos de alta generación y baja demanda para utilizarla en momentos de baja generación o alta demanda.

Mientras existe un consenso sobre los beneficios de utilizar almacenamiento *intradía* para aliviar las necesidades crecientes de equilibrio creadas por la generación renovable (Barton e Infield, 2004; O'Dwyer y Flynn, 2015), algunos autores también han empezado a argumentar a favor de la instalación de almacenamiento *interdía* en sistemas eléctricos con una alta proporción de producción de energía renovable (Denholm y Hand, 2011; Spiecker y Weber, 2014; Weitemeyer et al., 2015; Stiphout, Vaeck y Deconinck, 2016). Este tipo de tecnologías de almacenamiento se vuelven cruciales para superar los períodos de “calma oscura” que ocurren en Europa central, por ejemplo. Estos períodos se caracterizan por prolongadas condiciones climáticas de alta presión que reducen la generación de energía eólica a un mínimo, combinado con nubes, niebla o nieve que dificultan la generación de

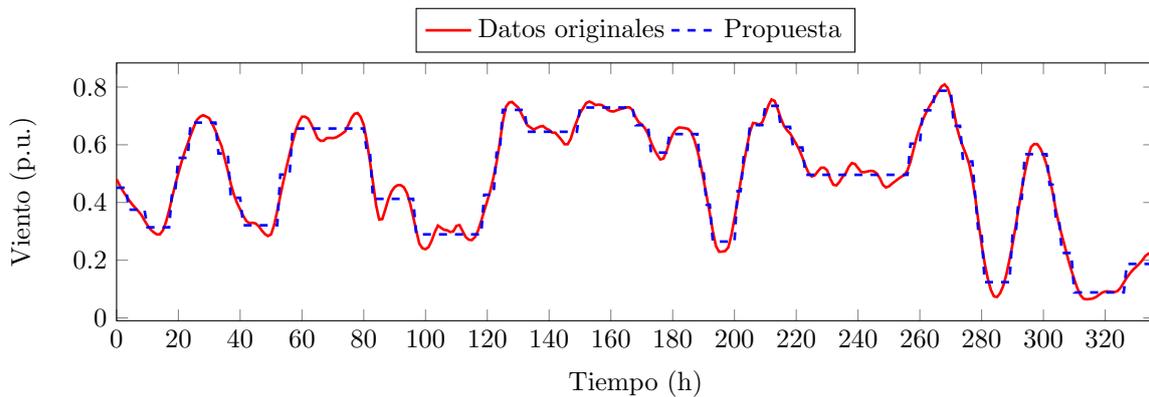


Fig. 3: Aproximación de la producción de energía eólica usando clusterización cronológica

energía solar (Fuchs et al., 2012). Sin embargo, hacer un seguimiento del nivel de energía de los dispositivos de almacenamiento interdía en los modelos de expansión de capacidad no es posible utilizando días representativos (Frew y Jacobson, 2016; Brijs et al., 2017). En consecuencia, la mayoría de los modelos existentes solo consideran tecnologías de almacenamiento intradía (Dvorkin et al., 2017; Liu, Sioshansi y Conejo, 2017; Wogrin y Gayme, 2015).

Además, se han dedicado esfuerzos crecientes al desarrollo de métodos computacionalmente eficientes para capturar la operación intertemporal del almacenamiento. Por ejemplo, los autores de (Tejada, Wogrin y Centeno, 2017) proponen un procedimiento heurístico de estado del sistema para aproximar el nivel de energía de los dispositivos de almacenamiento. Sin embargo, este procedimiento solo se puede aplicar, hasta la fecha, para problemas de operación del sistema eléctrico.

En este artículo proponemos un método para agrupar los períodos de tiempo de un modelo de expansión de capacidad mientras se mantiene, tanto como sea posible, la información cronológica de los parámetros dependientes del tiempo en todo el horizonte de planificación. Al hacerlo, el modelo resultante de expansión de capacidad es capaz de capturar las dinámicas más largas de la generación de energía renovable y modelar adecuadamente las restricciones de conservación de energía de los dispositivos de almacenamiento interdía. En resumen, el método propuesto realiza una agrupación jerárquica de horas consecutivas según medidas de distancia convencionales (Hastie, Tibshirani y Friedman, 2009). A modo de ilustración, la Figura 3 representa la agregación de períodos de tiempo del factor de capacidad eólica en Dinamarca durante las primeras dos semanas de 2010 siguiendo el procedimiento propuesto en este artículo y considerando 48 períodos de tiempo (es decir, el mismo número de períodos que en dos días representativos). Se puede observar que nuestro método aproxima con mayor precisión la variabilidad de la producción de energía eólica durante todo el horizonte de tiempo que el enfoque basado en dos días representativos, que se muestra en la Figura 2. Por lo tanto, las contribuciones de este artículo son las siguientes:

- La propuesta de una técnica de agrupación jerárquica modificada para agregar períodos de tiempo consecutivos según medidas de distancia convencionales.
- La formulación de un modelo de expansión de capacidad que determina la inversión óptima en generación convencional y renovable, tecnologías de almacenamiento intradía e interdía y líneas de transporte teniendo en cuenta las dinámicas de los parámetros dependientes del tiempo.

- La comparación del método de agregación de tiempo propuesto con los más comúnmente utilizados en la literatura técnica, que consisten en seleccionar días o semanas representativos utilizando técnicas de agrupamiento clásicas. Evaluamos el rendimiento de cada enfoque en términos de tiempo de computación y precisión de las decisiones de inversión en comparación con un modelo de referencia que no agrupa períodos de tiempo.

### 3. Metodología

Las técnicas de *clustering* consisten en agrupar una colección de objetos en subconjuntos o *clusters* de tal manera que los elementos de un cluster sean más similares entre sí que a los elementos de un cluster diferente (Hastie, Tibshirani y Friedman, 2009). En el contexto actual, las técnicas de clustering se utilizan comúnmente para seleccionar un número reducido de períodos de tiempo representativos (horas, días o semanas) con el fin de reducir la carga computacional de los modelos de planificación a largo plazo (Frew y Jacobson, 2016; Merrick, 2016; Munoz y A. D. Mills, 2015; Poncelet, Hoschle et al., 2017; Tejada, Wogrin y Centeno, 2017; Nicolosi, A. Mills y Wiser, 2010; Ploussard, Olmos y Ramos, 2016). Entre las diferentes técnicas, el clustering jerárquico es ampliamente utilizado porque su resultado no depende de la inicialización del algoritmo. A diferencia de otras técnicas de clustering como K-means, el clustering jerárquico también permite incluir fácilmente condiciones adicionales sobre cómo se fusionan los clusters. Por otro lado, el clustering jerárquico requiere una medida de disimilitud entre dos grupos de observaciones y un criterio de enlace para determinar qué clusters se fusionan o dividen (Hastie, Tibshirani y Friedman, 2009; Liu, Sioshansi y Conejo, 2017; Nahmmacher et al., 2016). Los métodos de agregación de períodos de tiempo que consideramos en este artículo, incluido el que proponemos, se basan en el método de Ward para el clustering jerárquico aglomerativo (Ward, 1963). En pocas palabras, el método de Ward fusiona de forma recursiva el par de clusters que incrementa mínimamente la varianza dentro del cluster. A continuación, explicamos los algoritmos de clustering utilizados por los métodos de agregación de períodos de tiempo considerados en este artículo.

Sea  $N$  el número total de días/semanas del horizonte de planificación. Sea  $\mathbf{x}_i$  un vector que contiene los valores normalizados de todos los parámetros dependientes del tiempo para el día/semana  $i$ . Por ejemplo, si se consideran la demanda y la velocidad del viento para dos ubicaciones diferentes, el vector  $\mathbf{x}_i$  tendría  $2 \times 2 \times 24$  o  $2 \times 2 \times 168$  elementos para cada día o semana, respectivamente. Los pasos para seleccionar  $N'$  días/semanas representativos utilizando clustering jerárquico aglomerativo son los siguientes:

1. Establecer el número inicial de clusters  $n$  como el número total de días/semanas  $N$ .
2. Determinar el centroide  $\bar{\mathbf{x}}_I$  de cada cluster  $I$  como

$$\bar{\mathbf{x}}_I = \frac{1}{|I|} \sum_{i \in I} \mathbf{x}_i \quad (1)$$

3. Calcular la disimilitud entre cada par de clusters  $I, J$  según el método de Ward de la siguiente manera (Ward, 1963)

$$D(I, J) = \frac{2|I||J|}{|I| + |J|} \|\bar{\mathbf{x}}_I - \bar{\mathbf{x}}_J\|^2 \quad (2)$$

4. Fusionar los dos clusters más cercanos  $(I', J')$  según la matriz de disimilitud, es decir,  $(I', J') \in \arg \min D(I, J)$  s.t.  $I \neq J$ .

5. Actualizar  $n \leftarrow n - 1$ .
6. Si  $n = N'$  ir al paso 7). De lo contrario, ir al paso 2).
7. Determinar el conjunto de días/semanas representativos como los medoides de los clusters, es decir, los elementos con la disimilitud mínima respecto al resto de elementos en cada cluster.

Este procedimiento de clustering jerárquico aglomerativo es el utilizado para seleccionar dos días representativos de los catorce días considerados en las Figuras 1 y 2. También es el método mediante el cual elegimos los días/semanas representativos para el modelo de expansión de capacidad descrito en la Sección 4. A continuación, presentamos el método de clustering cronológico propuesto. Sea  $N$  y  $N'$  el número inicial y reducido de períodos de tiempo del horizonte de planificación. Los pasos para implementar el algoritmo propuesto son los siguientes:

1. Establecer el número inicial de clusters  $n$  como el número total de horas  $N$ .
2. Determinar el centroide  $\bar{x}_I$  de cada cluster  $I$  utilizando (1).
3. Calcular la disimilitud entre cada par de clusters adyacentes  $I, J$  según el método de Ward utilizando (2).
4. Fusionar los dos clusters adyacentes más cercanos  $(I', J')$  según la matriz de disimilitud, es decir,  $(I', J') \in \arg \min D(I, J)$  s.t.  $J \in \mathcal{A}(I)$ , donde  $\mathcal{A}(I)$  es el conjunto de clusters adyacentes al cluster  $I$ . Dos clusters  $I$  y  $J$  se consideran adyacentes si  $I$  contiene una hora que es consecutiva a una hora en  $J$ , o viceversa, según la serie de tiempo original.
5. Actualizar  $n \leftarrow n - 1$ .
6. Si  $n = N'$  ir al paso 7). De lo contrario, ir al paso 2).
7. Determinar el conjunto de períodos representativos como los centroides de los clusters  $\bar{x}_I$ .

Este es el algoritmo de clustering utilizado para agrupar el factor de capacidad eólica de dos semanas representado en la subgráfica inferior de la Figura 3 utilizando 48 períodos de tiempo. En este artículo consideramos un modelo de expansión de capacidad que determina el tamaño óptimo, tipo y ubicación de tecnologías de generación, dispositivos de almacenamiento de energía y la capacidad de las líneas de transporte para alcanzar una determinada participación de generación de energía renovable al coste mínimo. Por simplicidad, el modelo propuesto proporciona decisiones de expansión de capacidad para un solo año objetivo. El modelo de expansión de capacidad se formula como un problema determinista de optimización y, por lo tanto, no se tiene en cuenta la incertidumbre de los parámetros de entrada. Con el fin de mantener la viabilidad computacional del modelo de planificación de expansión dentro de límites razonables, las decisiones de inversión se modelan como variables continuas. La formulación del modelo de expansión de capacidad puede consultarse en la referencia (Pineda y Morales, 2018), la cual es utilizada para evaluar el rendimiento de diferentes algoritmos de agregación de períodos de tiempo. Para ello, definimos los siguientes cuatro modelos:

- Modelo completo, denotado como "F". Se consideran todas las horas del horizonte de planificación y por lo tanto se pueden imponer restricciones que involucren períodos de tiempo consecutivos. Este modelo es el de referencia.

- Modelo basado en días representativos, que denotamos como “D- $N_D$ ”, donde  $N_D$  es el número de días representativos. Cada uno de estos días consta de 24 valores horarios de los datos de entrada y el peso de cada día representativo se determina según el algoritmo de clustering descrito en esta sección. Dado que los días representativos no son necesariamente consecutivos, las restricciones inter-temporales no se pueden aplicar a la primera hora y última hora de cada uno de estos días.
- Modelo basado en semanas representativas, denominado “W- $N_W$ ”, donde  $N_W$  es el número de semanas representativas elegidas siguiendo el mismo razonamiento que para el modelo con días representativos.
- Modelo de agregación cronológica de períodos de tiempo, al que nos referimos como “C- $N_T$ ”, donde  $N_T$  es el número de períodos de tiempo reducidos. Este modelo se basa en la agregación de períodos de tiempo consecutivos y la duración de cada periodo agregado se determina mediante el procedimiento de clustering presentado en esta sección. Dado que se mantiene la cronología, en este modelo se pueden imponer restricciones que involucren períodos de tiempo consecutivos en todo el horizonte de planificación.

#### 4. Resultados

A continuación, analizamos el rendimiento de los cuatro modelos descritos en la Sección 3 para determinar la planificación óptima del sistema eléctrico europeo para el año 2030. Para resaltar las diferencias entre estos métodos, resolvemos el problema de planificación partiendo de un sistema sin capacidad existente para generación, transporte o almacenamiento. De hecho, las discrepancias entre los métodos se diluirían si se tuvieran en cuenta las capacidades existentes en la actualidad.

Consideramos dos tecnologías de generación convencional, a saber, una tecnología *base* y una tecnología de *pico*. La tecnología base tiene un menor coste de combustible pero es menos flexible, mientras que la tecnología pico es más flexible pero presenta un mayor coste de producción. También se consideran los costes de inversión en capacidad de energía eólica y solar, ambas con un coste de combustible igual a 0. También tenemos en cuenta la posibilidad de instalar tecnologías de almacenamiento intradía e interdía. La tecnología de almacenamiento intradía tiene un menor coste de inversión y una mayor eficiencia, mientras que la capacidad de almacenamiento de energía es mayor en la tecnología de almacenamiento interdía. Cada país se representa como un único bus y, por lo tanto, el sistema eléctrico europeo se modela como una red de 28 buses. El coste de inversión de las líneas de transporte se establece en €1000/MW·km, con una vida útil de 50 años. Para trabajar con valores razonables de demanda de electricidad en 2030, consideramos un crecimiento anual de la demanda del 1%, a partir de 2010. Esto significa que se asume que la demanda de electricidad en Europa en 2030 es un 20% más alta que en 2010. Todos los datos del sistema europeo están disponibles en (Pineda y Morales, 2018).

La Figura 4 representa el coste total asociado a los planes de expansión de cada una de las técnicas de agrupamiento consideradas en función del nivel de integración de energía renovable en el suministro eléctrico. Cabe destacar que la técnica de agrupamiento propuesta (C-672) da lugar a costes significativamente inferiores a las otras dos (D-28 y W-4) en casi todos los niveles de participación. Además, la reducción de coste alcanzada por el método propuesto se vuelve cada vez más significativa a medida que aumenta la integración de la generación eléctrica con fuentes de energía renovable. Conforme el suministro de electricidad depende cada vez más de la generación de energía eólica y solar, se vuelve más relevante la modelización precisa de la operación de los sistemas de almacenamiento de

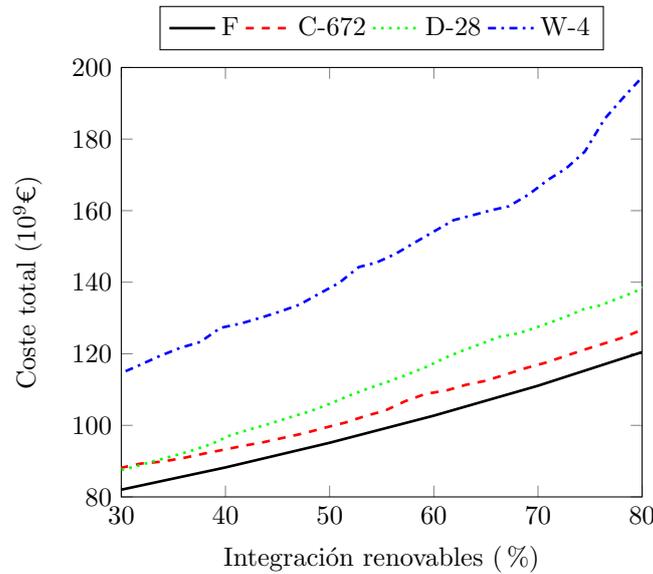


Fig. 4: Comparación del coste total para diferentes niveles de integración de renovables

energía. Por definición, el enfoque basado en días representativos no puede modelar el almacenamiento interdiario y, por lo tanto, el coste resultante de este método es comparativamente más alto. El aumento en el coste de la técnica de agrupamiento basada en semanas representativas se debe a una razón diferente. Aunque este enfoque es capaz de modelar parcialmente los beneficios del almacenamiento interdiario, este método no es capaz de capturar los picos de demanda neta en el sistema, lo que empeora notablemente su rendimiento.

Para cuantificar y resumir la información proporcionada por la Figura 4, definimos el *error promedio de coste* de la siguiente manera:

$$\bar{\Delta}^* = \frac{\overline{\text{Coste}}^* - \overline{\text{Coste}}^F}{\overline{\text{Coste}}^F} \times 100$$

donde  $\overline{\text{Coste}}^*$ , con  $*$  = D, W, C, es el coste total del plan de expansión asociado al método de agrupamiento “\*” promediado sobre todos los niveles de participación renovable entre el 30% y el 80%. Por ejemplo, los errores promedio de coste correspondientes a C-672, D-28 y W-4 son 6.1%, 13.1% y 48.1%, respectivamente.

A continuación, investigamos el rendimiento de los métodos comparados en este artículo para un número creciente de períodos de tiempo, días representativos y semanas representativas. Para ello, la Figura 5 presenta el error promedio de coste  $\bar{\Delta}^*$  en función del número de períodos  $N_T$  en los que se divide todo el año 2030. Para los métodos basados en días y semanas representativas,  $N_T$  se calcula como  $24 \times N_D$  y  $168 \times N_W$ , respectivamente. En esta figura puede observarse que el error promedio de la técnica de agrupación cronológica por períodos de tiempo es notablemente menor que el de los otros dos métodos de agrupación para un amplio rango del número de períodos. Por ejemplo, el número de períodos requeridos para mantener el error promedio de costo por debajo del 6% son, aproximadamente, 3300, 2600 y 700 para los métodos D, W y C, respectivamente. Además, la técnica de agrupación basada en la selección de semanas representativas es la que más se beneficia

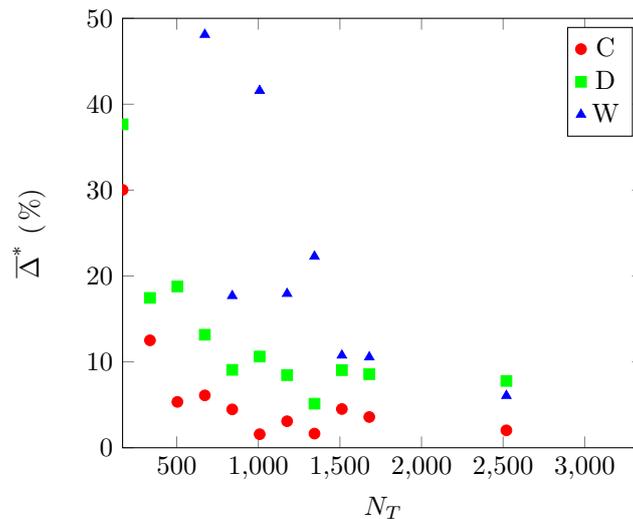


Fig. 5: Error promedio de coste en función del número de períodos

en términos relativos al aumentar el número de períodos, superando el rendimiento del método de agrupación basado en días representativos cuando el número de períodos es suficientemente alto.

A pesar de las importantes discrepancias en el rendimiento presentadas por los tres métodos de agrupación, todos ellos implican cargas computacionales del mismo orden de magnitud, como se destaca en la Figura 6. Cabe resaltar que el tiempo computacional mostrado en esta figura tiene en cuenta tanto el tiempo requerido por el método de agrupación como el tiempo necesario para resolver el modelo de planificación, aunque el primero es muy insignificante en comparación con el último. Además, el tiempo promedio necesario para resolver el modelo de planificación considerando el conjunto completo de períodos horarios es de aproximadamente diez horas, lo que destaca la capacidad de los tres algoritmos de agrupación para acelerar notablemente el proceso de solución. Los resultados de simulación de este estudio de caso se han obtenido utilizando CPLEX 12.6.3 con Pyomo 5.2 en un servidor basado en Linux con una CPU a 2.6 GHz y 20 GB de RAM.

Para concluir esta sección, analizamos el rendimiento de cada técnica de agrupación de períodos en cuatro escenarios diferentes. En cada uno de estos escenarios excluimos la posibilidad de instalar cierto tipo de tecnología. De esta manera, denominamos a estos escenarios como *No.wind*, *No.solar*, *No.hydro* y *No.storage*, donde el nombre corto indica qué tecnología se ha excluido. La Tabla 1 incluye el error promedio de costes incurrido por los tres algoritmos de agrupación en los cuatro escenarios considerados. Se puede observar que el método propuesto supera significativamente a los demás en dos de los cuatro escenarios, a saber, *No.solar* y *No.hydro*, mientras que muestra un rendimiento inferior en los escenarios *No.wind* y *No.storage*. Para entender estos resultados, debemos tener en cuenta que el método de agrupación cronológico de períodos de tiempo propuesto retiene las dinámicas a medio plazo de las series de tiempo de entrada y permite una modelización más precisa de la operación del almacenamiento interdía. De hecho, la ventaja del enfoque propuesto radica precisamente en la estrecha interacción de estos dos aspectos, es decir, en su capacidad para capturar el valor de utilizar el almacenamiento interdía para integrar la generación renovable. Por otro lado, el enfoque propuesto pierde información sobre las variaciones hora a hora de los parámetros dependientes del tiempo, como se ilustra en la Figura 3.

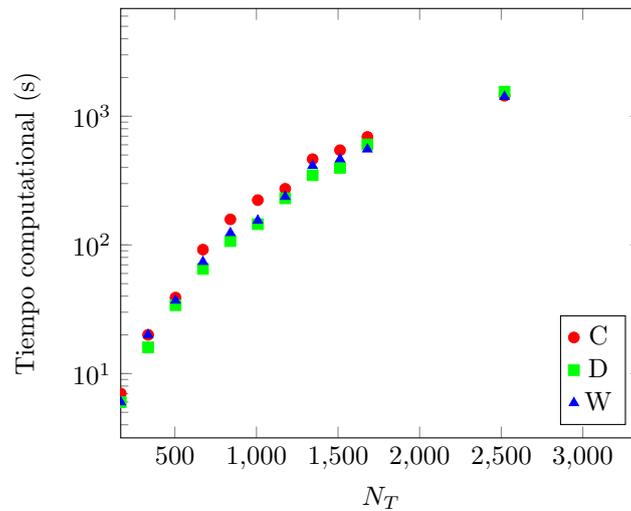


Fig. 6: Tiempo computacional

El escenario *No\_wind* se caracteriza por dos entradas dependientes del tiempo (solar y demanda) con patrones diarios fuertes. En tal caso, el valor del almacenamiento interdía es bajo, la modelización precisa de las variaciones hora a hora se vuelve relativamente más relevante y, como resultado, el enfoque propuesto tiene un rendimiento peor que el método basado en la selección de días representativos. En el escenario *No\_storage*, la instalación de almacenamiento simplemente no es una posibilidad y, en consecuencia, el enfoque propuesto resulta en el mayor error promedio de costes. Por el contrario, el valor del almacenamiento interdía es comparativamente muy significativo en los escenarios *No\_solar* y *No\_hydro*, donde se excluyen las inversiones en generación de energía solar e hidroeléctrica, y, por lo tanto, el enfoque propuesto tiene un rendimiento mucho mejor que los otros métodos en estos dos escenarios.

Escenario	C-672	D-28	W-4
No_solar	8.6 %	18.3 %	31.5 %
No_wind	9.0 %	7.2 %	32.8 %
No_hydro	2.3 %	13.2 %	60.3 %
No_storage	11.1 %	7.2 %	6.3 %

Tab. 1: Errores de coste promedio en diferentes escenarios

## 5. Conclusiones

La mayoría de los métodos existentes de agregación de períodos de tiempo tienen como objetivo reducir la carga computacional de los problemas de expansión de capacidad a través de la selección de un conjunto de horas, días o semanas representativas del horizonte de planificación. Estos métodos no capturan adecuadamente las dinámicas a medio plazo de las fuentes de energía renovable, como la energía eólica, y no modelan con precisión la operación de las tecnologías de almacenamiento de electricidad. Para superar estas limitaciones, en este artículo proponemos una nueva técnica

de agrupación de períodos de tiempo que conserva la cronología de los parámetros dependientes del tiempo a lo largo de todo el horizonte de planificación. De esta manera, el método propuesto determina planes de expansión de capacidad que tienen en cuenta el valor económico de utilizar el almacenamiento interdiario para operar de manera más eficiente el sistema eléctrico durante períodos prolongados de alta o baja generación de energía renovable.

Utilizando la red eléctrica europea, comparamos el método propuesto con otros existentes en términos de su error promedio de costes con respecto a un modelo de expansión de capacidad de referencia que trabaja con el conjunto completo de períodos de tiempo. Los resultados numéricos muestran el rendimiento superior de nuestro método, que determina planes de expansión de capacidad más eficientes que los impulsados por los métodos existentes sin aumentar la carga computacional. En particular, el error promedio de costes considerando 672 períodos de tiempo es de 13.1 %, 48.1 % y 6.1 % para los métodos basados en días representativos, semanas representativas y la técnica de agrupación propuesta, respectivamente. Utilizando la red eléctrica europea en diferentes escenarios, también ilustramos que el rendimiento de la agrupación cronológica de períodos empeora para los sistemas de energía que no esperan incluir generación de energía renovable con dinámicas a medio plazo (como la eólica) o dispositivos de almacenamiento de energía. Sin embargo, considerando la tendencia mundial hacia sistemas de energía dominados por renovables, con diversas formas de almacenamiento, el método de agrupación propuesto resulta ser una forma eficiente y efectiva de facilitar la solución de modelos de expansión a gran escala.

Como se muestra en la Figura 3, la agrupación cronológica de períodos suaviza las series de tiempo de entrada y, por lo tanto, filtra sus dinámicas a corto plazo (por ejemplo, valores máximos de corta duración). Cómo mejorar o complementar la técnica de agrupación propuesta para tener en cuenta plenamente las dinámicas a corto plazo de las series de tiempo de entrada en los modelos de expansión de capacidad queda como investigación futura. Otro tema que requiere una mayor investigación es cómo adaptar el procedimiento de agregación de tiempo aquí propuesto para tener en cuenta la incertidumbre de los parámetros dependientes del tiempo.

## Agradecimientos

Este proyecto ha sido financiado en parte por el Ministerio de Ciencia e Innovación de España (AEI/10.13039/501100011033) a través del proyecto PID2020-115460GB-I00, y en parte por el Consejo Europeo de Investigaciones Científicas (ERC) en el marco del Programa de Investigación e Innovación *Horizon 2020* de la Unión Europea (acuerdo de subvención No. 755705). Los autores agradecen también los recursos informáticos, la experiencia técnica y la asistencia proporcionada por el centro SCBI (Supercomputación y Bioinformática) de la Universidad de Málaga.

## Sobre los autores



**Salvador Pineda** obtuvo el título de Ingeniero Industrial de la Universidad de Málaga, Málaga, España, en 2006, y el título de Doctor en Ingeniería Eléctrica de la Universidad de Castilla-La Mancha, Ciudad Real, España, en 2011. Actualmente es Profesor Titular en el Departamento de Ingeniería Eléctrica de la Universidad de Málaga, España. Sus intereses de investigación incluyen la operación y planificación de sistemas eléctricos, la toma de decisiones bajo incertidumbre, la programación bilevel, el aprendizaje automático y la estadística.



**Juan Miguel Morales** obtuvo el título de Ingeniero Industrial por la Universidad de Málaga, Málaga, España, en 2006, y el título de Doctor en Ingeniería Eléctrica por la Universidad de Castilla-La Mancha, Ciudad Real, España, en 2010. Actualmente es Profesor Titular en el Departamento de Matemática Aplicada de la Universidad de Málaga, España. Sus áreas científicas de interés abarcan la Optimización Matemática, la toma de decisiones bajo incertidumbre; y la economía, operación y planificación de las redes inteligentes de energía.

## Referencias

- Barton, John P. y David G. Infield (jun. de 2004). «Energy storage and its use with intermittent renewable energy». En: *IEEE Transactions on Energy Conversion* 19.2, págs. 441-448. ISSN: 08858969. DOI: [10.1109/TEC.2003.822305](https://doi.org/10.1109/TEC.2003.822305). URL: <http://ieeexplore.ieee.org/document/1300713/>.
- Beaudin, Marc, Hamidreza Zareipour, Anthony Schellenberglabe y William Rosehart (2010). «Energy storage for mitigating the variability of renewable electricity sources: An updated review». En: *Energy for Sustainable Development* 14.4, págs. 302-314. DOI: [10.1016/j.esd.2010.09.007](https://doi.org/10.1016/j.esd.2010.09.007). URL: <http://www.sciencedirect.com/science/article/pii/S0973082610000566>.
- Brijs, Tom, Arne van Stiphout, Sauleh Siddiqui y Ronnie Belmans (2017). «Evaluating the role of electricity storage by considering short-term operation in long-term planning». En: *Sustainable Energy, Grids and Networks* 10, págs. 104-117. ISSN: 23524677. DOI: [10.1016/j.segan.2017.04.002](https://doi.org/10.1016/j.segan.2017.04.002). URL: <http://www.sciencedirect.com/science/article/pii/S2352467716301102%20http://linkinghub.elsevier.com/retrieve/pii/S2352467716301102>.
- Denholm, Paul y Maureen Hand (2011). «Grid flexibility and storage required to achieve very high penetration of variable renewable electricity». En: *Energy Policy* 39.3, págs. 1817-1830. ISSN: 03014215. DOI: [10.1016/j.enpol.2011.01.019](https://doi.org/10.1016/j.enpol.2011.01.019). URL: <http://www.sciencedirect.com/science/article/pii/S0301421511000292>.
- Dvorkin, Yury, Ricardo Fernandez-Blanco, Daniel S. Kirschen, Hrvoje Pandžić, Jean Paul Watson y Cesar A. Silva-Monroy (2017). «Ensuring Profitability of Energy Storage». En: *IEEE Transactions on Power Systems* 32.1, págs. 611-623. ISSN: 08858950. DOI: [10.1109/TPWRS.2016.2563259](https://doi.org/10.1109/TPWRS.2016.2563259). URL: <http://ieeexplore.ieee.org/document/7464891/>.

- ElNozahy, M. S., M. M. A. Salama y R. Seethapathy (2013). «A probabilistic load modelling approach using clustering algorithms». En: *2013 IEEE Power & Energy Society General Meeting*. IEEE, págs. 1-5. ISBN: 978-1-4799-1303-9. DOI: [10.1109/PESMG.2013.6672073](https://doi.org/10.1109/PESMG.2013.6672073). URL: <http://ieeexplore.ieee.org/document/6672073/%20http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6672073>.
- Frew, Bethany A. y Mark Z. Jacobson (2016). «Temporal and spatial tradeoffs in power system modeling with assumptions about storage: An application of the POWER model». En: *Energy* 117, págs. 198-213. ISSN: 03605442. DOI: [10.1016/j.energy.2016.10.074](https://doi.org/10.1016/j.energy.2016.10.074). URL: <http://www.sciencedirect.com/science/article/pii/S0360544216315110>.
- Fuchs, Georg, Benedikt Lunz, Matthias Leuthold y Dirk Uwe Sauer (2012). *Technology Overview on Electricity Storage*. Inf. téc. June, pág. 66. URL: [http://www.sefep.eu/activities/projects-studies/120628\\_Technology\\_Overview\\_Electricity\\_Storage\\_SEFEP\\_ISEA.pdf](http://www.sefep.eu/activities/projects-studies/120628_Technology_Overview_Electricity_Storage_SEFEP_ISEA.pdf).
- Hastie, T, R Tibshirani y J Friedman (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction, Second Edition*. Springer Series in Statistics. Springer New York. ISBN: 9780387848587. URL: <https://books.google.es/books?id=tVIjmNS30b8C>.
- Hemmati, Reza, Rahmat-Allah Hooshmand y Amin Khodabakhshian (sep. de 2013). «Comprehensive review of generation and transmission expansion planning». En: *IET Generation, Transmission & Distribution* 7.9, págs. 955-964. ISSN: 1751-8687. DOI: [10.1049/iet-gtd.2013.0031](https://doi.org/10.1049/iet-gtd.2013.0031). URL: <http://digital-library.theiet.org/content/journals/10.1049/iet-gtd.2013.0031>.
- Koltsaklis, Nikolaos E. y Michael C. Georgiadis (2015). «A multi-period, multi-regional generation expansion planning model incorporating unit commitment constraints». En: *Applied Energy* 158, págs. 310-331. ISSN: 03062619. DOI: [10.1016/j.apenergy.2015.08.054](https://doi.org/10.1016/j.apenergy.2015.08.054).
- Liu, Yixian, Ramteen Sioshansi y Antonio J Conejo (2017). «Hierarchical Clustering to Find Representative Operating Periods for Capacity-Expansion Modeling». En: *IEEE Trans. Power Syst.* 99, págs. 1-8.
- Merrick, James H. (2016). «On representation of temporal variability in electricity capacity planning models». En: *Energy Economics* 59, págs. 261-274. ISSN: 01409883. DOI: [10.1016/j.eneco.2016.08.001](https://doi.org/10.1016/j.eneco.2016.08.001). URL: <http://dx.doi.org/10.1016/j.eneco.2016.08.001>.
- Munoz, Francisco D. y Andrew D. Mills (oct. de 2015). «Endogenous Assessment of the Capacity Value of Solar PV in Generation Investment Planning Studies». En: *IEEE Transactions on Sustainable Energy* 6.4, págs. 1574-1585. ISSN: 19493029. DOI: [10.1109/TSST.2015.2456019](https://doi.org/10.1109/TSST.2015.2456019). URL: <http://ieeexplore.ieee.org/document/7182348/>.
- Murphy, F. H. e Y. Smeers (2005). «Generation Capacity Expansion in Imperfectly Competitive Restructured Electricity Markets». En: *Operations Research* 53.4, págs. 646-661. DOI: [10.1287/opre.1050.0211](https://doi.org/10.1287/opre.1050.0211). URL: <http://dx.doi.org/10.1287/opre.1050.0211>.
- Nahmmacher, Paul, Eva Schmid, Lion Hirth y Brigitte Knopf (2016). «Carpe diem: A novel approach to select representative days for long-term power system modeling». En: *Energy* 112, págs. 430-442. ISSN: 03605442. DOI: [10.1016/j.energy.2016.06.081](https://doi.org/10.1016/j.energy.2016.06.081).
- Nicolosi, Marco, Andrew Mills y Ryan Wiser (2010). «The Importance of High Temporal Resolution in Modeling Renewable Energy Penetration Scenarios». En: *9th- Conference on Applied Infrastructure Research*. DOI: [LBNLPaperLBNL-4197E](https://doi.org/LBNLPaperLBNL-4197E). URL: <http://escholarship.org/uc/item/9rh9v9t4.pdf>.
- O'Dwyer, Ciara y Damian Flynn (jul. de 2015). «Using Energy Storage to Manage High Net Load Variability at Sub-Hourly Time-Scales». En: *IEEE Transactions on Power Systems* 30.4, págs. 2139-2148. ISSN: 08858950. DOI: [10.1109/TPWRS.2014.2356232](https://doi.org/10.1109/TPWRS.2014.2356232). URL: <http://ieeexplore.ieee.org/document/6912022/>.
- Pandzic, Hrvoje, Yishen Wang, Ting Qiu, Yury Dvorkin y Daniel S. Kirschen (2015). «Near-Optimal Method for Siting and Sizing of Distributed Storage in a Transmission Network». En: *IEEE*

- Transactions on Power Systems* 30.5, págs. 2288-2300. ISSN: 08858950. DOI: [10.1109/TPWRS.2014.2364257](https://doi.org/10.1109/TPWRS.2014.2364257).
- Pineda, Salvador y Juan M Morales (2018). «Chronological time-period clustering for optimal capacity expansion planning with storage». En: *IEEE Transactions on Power Systems* 33.6, págs. 7162-7170.
- Ploussard, Quentin, Luis Olmos y Andres Ramos (2016). «An operational state aggregation technique for transmission expansion planning based on line benefits». En: *IEEE Transactions on Power Systems*, págs. 1-12. ISSN: 0885-8950. DOI: [10.1109/TPWRS.2016.2614368](https://doi.org/10.1109/TPWRS.2016.2614368). URL: <http://ieeexplore.ieee.org/document/7582509/>.
- Poncelet, Kris, Erik Delarue, Daan Six, Jan Duerinck y William D'haeseleer (2016). «Impact of the level of temporal and operational detail in energy-system planning models». En: *Applied Energy* 162, págs. 631-643. ISSN: 03062619. DOI: [10.1016/j.apenergy.2015.10.100](https://doi.org/10.1016/j.apenergy.2015.10.100).
- Poncelet, Kris, Hanspeter Hoshle, Erik Delarue, Ana Virag y William D'haeseleer (2017). «Selecting Representative Days for Capturing the Implications of Integrating Intermittent Renewables in Generation Expansion Planning Problems». En: *IEEE Transactions on Power Systems* 32.3, págs. 1936-1948. ISSN: 0885-8950. DOI: [10.1109/TPWRS.2016.2596803](https://doi.org/10.1109/TPWRS.2016.2596803). URL: <http://ieeexplore.ieee.org/document/7527691/>.
- Roh, Jae Hyung, Mohammad Shahidehpour y Lei Wu (2009). «Market-based generation and transmission planning with uncertainties». En: *IEEE Transactions on Power Systems* 24.3, págs. 1587-1598.
- Sisternes, Fernando J. de, Jesse D. Jenkins y Audun Botterud (2016). «The value of energy storage in decarbonizing the electricity sector». En: *Applied Energy* 175, págs. 368-379. ISSN: 03062619. DOI: [10.1016/j.apenergy.2016.05.014](https://doi.org/10.1016/j.apenergy.2016.05.014).
- Spiecker, Stephan y Christoph Weber (2014). «The future of the European electricity system and the impact of fluctuating renewable energy - A scenario analysis». En: *Energy Policy* 65, págs. 185-197. ISSN: 03014215. DOI: [10.1016/j.enpol.2013.10.032](https://doi.org/10.1016/j.enpol.2013.10.032).
- Stiphout, Arne van, Sander Vaeck y Geert Deconinck (abr. de 2016). «The Role of Long-Term Energy Storage in Investment Planning of Renewable Power Systems». En: *IEEE International Energy Conference (ENERGYCON)*. IEEE, págs. 1-6. ISBN: 9781509012985. DOI: [10.1109/TPWRS.2016.2565058](https://doi.org/10.1109/TPWRS.2016.2565058). URL: <http://ieeexplore.ieee.org/document/7514035/>.
- Tejada, Diego A., Sonja Wogrin y Efraim Centeno (2017). «Representation of Storage Operations in Network-Constrained Optimization Models for Medium- and Long-Term Operation». En: *IEEE Transactions on Power Systems* 99, págs. 1-1. ISSN: 0885-8950. DOI: [10.1109/TPWRS.2017.2691359](https://doi.org/10.1109/TPWRS.2017.2691359). URL: <http://ieeexplore.ieee.org/document/7892923/>.
- Ward, Joe H. (mar. de 1963). *Hierarchical grouping to optimize an objective function*. DOI: [10.1080/01621459.1963.10500845](https://doi.org/10.1080/01621459.1963.10500845). URL: <http://www.tandfonline.com/doi/abs/10.1080/01621459.1963.10500845>.
- Weitemeyer, Stefan, David Kleinhans, Thomas Vogt y Carsten Agert (2015). «Integration of Renewable Energy Sources in future power systems: The role of storage». En: *Renewable Energy* 75, págs. 14-20. ISSN: 18790682. DOI: [10.1016/j.renene.2014.09.028](https://doi.org/10.1016/j.renene.2014.09.028).
- Wogrin, Sonja y Dennice F. Gayme (2015). «Optimizing Storage Siting, Sizing, and Technology Portfolios in Transmission-Constrained Networks». En: *IEEE Transactions on Power Systems* 30.6, págs. 3304-3313. ISSN: 08858950. DOI: [10.1109/TPWRS.2014.2379931](https://doi.org/10.1109/TPWRS.2014.2379931). URL: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6994829>.

