

# FRAMEWORK PARA LA PREDICCIÓN DE GENERACIÓN Y CONSUMO ELÉCTRICO A CORTO PLAZO APLICANDO MODELOS COMBINADOS DE LÍNEA BASE Y REGRESIÓN

**Antonio Parejo<sup>1</sup>, Stefano Bracco<sup>2</sup>, Enrique Personal<sup>1</sup>, Diego Francisco Larios<sup>1</sup>, Carlos León<sup>1</sup>, Sebastián García<sup>1</sup>**

<sup>1</sup>*Departamento de Tecnología Electrónica, Escuela Politécnica Superior, Universidad de Sevilla, Sevilla*

<sup>2</sup>*Dipartimento di Ingegneria Navale, Elettrica, Elettronica e delle Telecomunicazioni (DITEN), Campus universitario di Savona, Università Degli Studi Di Genova, Genova*

E-mail de correspondencia: [aparejo@us.es](mailto:aparejo@us.es)

## RESUMEN

La predicción de generación y consumo eléctrico a corto plazo supone una herramienta de enorme interés dentro del sistema eléctrico, donde la presencia de fuentes de generación renovable y distribuida está en constante crecimiento. Específicamente, este tipo de predicción es esencial para la gestión energética en edificios, industrias y microgrids para optimizar la operación de sus recursos energéticos bajo diferentes criterios. Teniendo esto en cuenta, se ha propuesto un framework completo para la predicción de generación y consumo en smart grids y microgrids. Concretamente, este framework se utiliza para comparar un conjunto de técnicas basadas en reglas y aprendizaje automático (machine learning) para realizar la predicción de variables eléctricas del día siguiente. Además, se presenta un enfoque novedoso que incluye el uso de modelos de línea base como entradas para los modelos de machine learning. Los resultados obtenidos indican que este enfoque mejora significativamente la predicción frente al resto de técnicas comparadas, logrando una mejora de hasta el 62% con respecto al método Naive. Estos resultados se han obtenido al aplicar la metodología propuesta para predecir cinco variables de potencia de generación y consumo eléctrico del Campus de Savona de la Universidad de Génova en Italia.

## 1. INTRODUCCIÓN

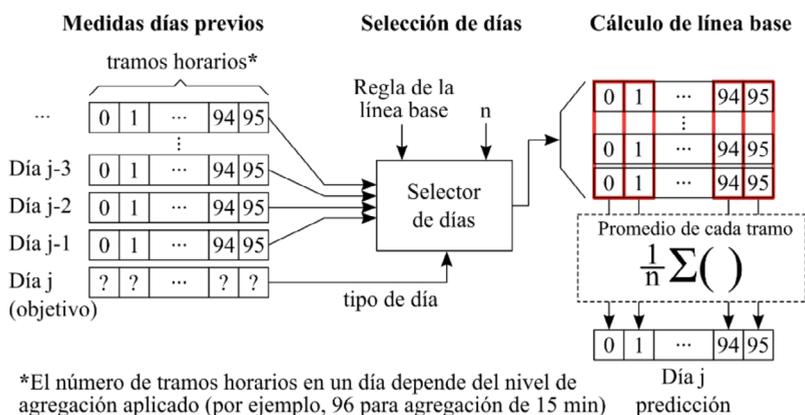
En los últimos años la presencia de fuentes de generación renovable dentro del sistema eléctrico se ha incrementado enormemente. Estas fuentes, además, se están integrando en gran parte de forma distribuida, esto es, conectándose directamente a las redes de distribución en lugar de a las redes de transporte. Esta generación distribuida constituye un paradigma de gran importancia dentro de la red eléctrica inteligente (*smart grid*), permitiendo una mejor integración de recursos de energía distribuidos (*distributed energy resources*, DERs). Para la gestión de estos recursos,

se requiere de una predicción de cuáles serán los niveles de generación y consumo dentro de las redes eléctricas y las microgrids.

Por ello, se ha diseñado un framework para realizar la predicción a corto plazo de diversas variables de potencia eléctrica en microgrids, así como un nuevo modelo llamado línea base basada en reglas. Este modelo, así como otros dos modelos de machine learning adicionales, se han utilizado en el estudio de caso centrado en la microgrid del Campus de Savona de la Universidad de Génova (Parejo *et al.*, 2021).

## 2. METODOLOGÍA

El framework diseñado recibe como información de entrada datos históricos de los medidores eléctricos del campus, información del calendario (sobre días laborables, festivos, etc.) y datos de predicción climática para el día siguiente. Mediante estos datos se crean diversos modelos. Las líneas base basadas en reglas consisten en calcular el promedio de potencia del tramo horario en cuestión a partir de datos de días anteriores (véase Ilustración 1), los cuales se eligen en función de la regla y parámetros que se apliquen dando lugar a numerosas posibilidades (Parejo *et al.*, 2021). Además, el framework aplica dos tipos de modelo de aprendizaje automático (machine learning), concretamente redes neuronales y bosques aleatorios.



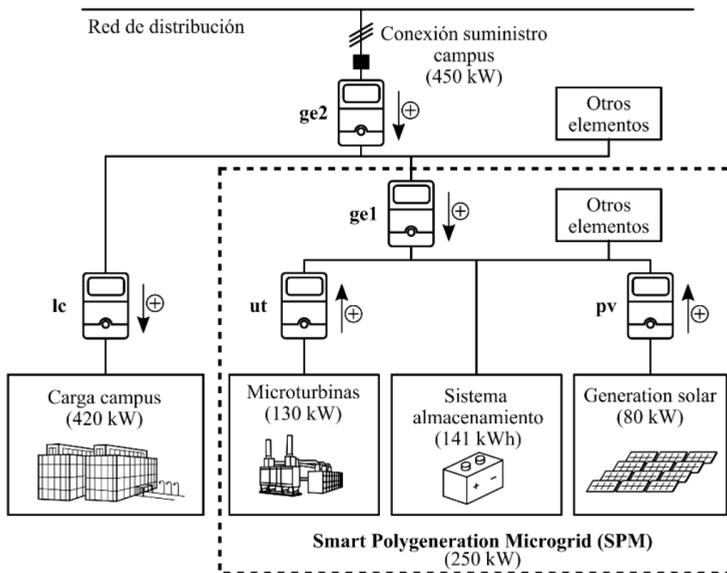
**Ilustración 1.** Modelos de línea base basados en reglas.

**Fuente:** elaboración propia.

Una innovación de esta propuesta, además de la creación de las líneas base basadas en reglas, es el uso de estas como entrada para los otros dos tipos de modelo. Como se verá más tarde en los resultados, esta realimentación (véase Ilustración 2) es capaz de mejorar los modelos de predicción.

### 3. RESULTADOS Y DISCUSIÓN

El estudio de caso en que se ha aplicado el framework propuesto se centra en el campus de Savona, que cuenta con una microgrid y con diversos recursos de generación propios, así como de un sistema de almacenamiento energético basado en baterías. En la Ilustración 2 puede verse un diagrama con los elementos de dicho campus.



**Ilustración 2.** Esquema eléctrico del Campus de Savona.

**Fuente:** elaboración propia.

Como se observa en dicha ilustración, las variables a predecir son  $ge1$ ,  $ge2$ ,  $lc$ ,  $ut$  y  $pv$ . Se ha realizado la comparativa de diversos modelos para las 5 variables, y para cada una ellas aplicando dos posibles niveles de agregación temporal, de 1 hora y de 15 minutos.

Por ejemplo, en el caso de la variable  $ge1$ , los resultados indican que el mejor modelo (aquel con menor valor de error) es uno de los que incluye realimentación de un modelo de línea base basado en reglas hacia un modelo de red neuronal. Por tanto, esta realimentación ha supuesto una mejora frente al resto de modelos probados (Parejo *et al.*, 2021).

Los resultados finales de los modelos, y su porcentaje de mejora con respecto al método de referencia (que ha sido la predicción mediante el método naive basado en el día anterior al día objetivo de la predicción) pueden verse en la Tabla 1.

**Tabla 1.** Resultados globales de error en los modelos.

| Variable a predecir | Agregación temporal | Modelo naive | Mejor modelo | Porcentaje mejora |
|---------------------|---------------------|--------------|--------------|-------------------|
|                     |                     | CV(RMSE) (%) | CV(RMSE) (%) | Mejora (%)        |
| ge1                 | 15 min              | 104.7        | 80.2         | 23                |
|                     | 1h                  | 101.3        | 77.4         | 24                |
| ge2                 | 15 min              | 51.5         | 28.7         | 44                |
|                     | 1h                  | 50.4         | 27.1         | 46                |
| ut                  | 15 min              | 89.7         | 69.9         | 22                |
|                     | 1h                  | 89.0         | 67.3         | 24                |
| lc                  | 15 min              | 36.2         | 14.8         | 59                |
|                     | 1h                  | 35.7         | 13.7         | 62                |
| pv                  | 15 min              | 96.6         | 65.1         | 33                |
|                     | 1h                  | 91.5         | 60.4         | 34                |

**Fuente:** elaboración propia.

## 4. CONCLUSIONES

Dada la importancia de la predicción para la correcta gestión de recursos en el sistema eléctrico, se ha realizado un framework de predicción a corto plazo para su aplicación en microgrids. La combinación de modelos de línea base basados en reglas con modelos de machine learning da como resultado una mejora en los modelos de predicción aplicados.

## AGRADECIMIENTOS

Los autores agradecen a la Universidad de Génova, y a los investigadores del Campus de Savona, por su ayuda y apoyo en la realización de este estudio. Este trabajo está financiado por el Ministerio de Ciencia, Innovación y Universidades de España mediante el proyecto “Bigdata Analytics e Instrumentación Cyberfísica para Soporte de Operaciones de Distribución en la Smart Grid” (referencia RTI2018-094917-B-I00). Antonio Parejo agradece además al Ministerio de Educación y Formación Profesional de España por su soporte económico mediante el contrato predoctoral FPU que le fue concedido (referencia FPU16/03522).

## REFERENCIAS BIBLIOGRÁFICAS

**Parejo, A., Bracco, S., Personal, E., Larios, D.F., León, C., García, S.** (2021). Short-Term Power Forecasting Framework for Microgrids Using Combined Baseline and Regression Models. *Applied Sciences*, 11(14). 6420. <https://doi.org/10.3390/app11146420>