UNIVERSIDAD DE ANTIOQUIA

Detección de Outliers en el Consumo de Energía en Telecomunicaciones

Yuliana Vanessa Rodríguez Posada

Proyecto de grado presentado como requisito para optar al título de Economista

Asesor interno
Santiago Alejandro Gallón

Asesora externa
Estefania Gomez Vera

Universidad de Antioquia
Facultad de Ciencias Económicas
Economía
Medellín,Colombia
2025

Cita	(Rodríguez Posada, 2025)
Referencia **Estilo APA 7 (2020)**	Rodríguez Posada, Y. V. (2025). Detección de Outliers en el consumo de energía en telecomunicaciones [Trabajo de grado profesional]. Universidad de Antioquia, Medellín, Colombia.



Especialización en Evaluación Económica en Salud, Cohorte V.





Centro de Documentación Economía

Repositorio Institucional: http://bibliotecadigital.udea.edu.co

El contenido de esta obra corresponde al derecho de expresión de los autores y no compromete el pensamiento institucional de la Universidad de Antioquia ni desata su responsabilidad frente a terceros. Los autores asumen la responsabilidad por los derechos de autor y conexos.

Índice

1. Contexto del problema y descripción de los datos **3**

1.1. ¿Qué se considera un outlier en este caso? 3

2. Revisión de literatura **4**

2.1. Enfoques clásicos para detección de outliers 4

2.2. Técnicas modernas y aprendizaje automático 4

2.3. Imputación de valores faltantes y tratamiento posterior a la detección 5

2.4. Predicción en escenarios inciertos y propuestas de estandarización 5

3. Exploración de datos **7**

4. Modelos Utilizados **9**

4.1. Isolation Forest 9

4.2. Prophet 9

5. Resultados **10**

5.1. ARA0001 10

5.2. ARM0011 11

6. Comparación de modelos **12**

7. Conclusiones **13**

8. Limitaciones y Recomendaciones **14**

Resumen:
Este trabajo explora el uso de modelos de detección de outliers en series de tiempo. El objetivo principal fue identificar comportamientos inusuales en los datos, utilizando dos enfoques diferentes: Prophet e Isolation Forest. Se analizaron visualmente los resultados de cada modelo, evaluando su comportamiento frente a diferentes patrones. Los hallazgos mostraron que ambos métodos ofrecen ventajas distintas: Prophet facilita la interpretación al incorporar estructura temporal, mientras que Isolation Forest realiza una detección más general. Se concluye que una combinación de enfoques y el análisis contextual pueden aportar valor a procesos de monitoreo energético.

Palabras clave: outliers, series temporales, consumo energético, Prophet, Isolation Forest

1. Contexto del problema y descripción de los datos

En este trabajo se utiliza como variable principal la *carga de energía completa* de los sitios de telecomunicaciones, medida en *kilovatios hora (kWh)*. Esta variable corresponde a la suma de dos componentes clave:

- **energycons_btsboard**: consumo de energía de la unidad de radio base (BTS) del sitio.
- **energycons_bu**: consumo de energía de la unidad de procesamiento (BU).

La suma de estas dos variables refleja el consumo energético total de los equipos principales del sitio. Por esta razón, la denominamos *energía completa*, y se espera que represente con precisión el comportamiento real de carga por sitio.

El análisis se enfoca en un rango de tiempo de doce meses, desde mayo de 2024 hasta mayo de 2025, con una granularidad diaria por sitio. Es decir, la unidad de análisis corresponde a un sitio por día.

El conjunto de datos está compuesto por un total de 3.207.173 registros provenientes de 14.338 sitios únicos. Si bien no se presentan valores faltantes en el sentido estricto (no hay sitios completamente vacíos ni registros con energía nula), sí existe cierta variabilidad en la cantidad de datos por sitio. Algunos sitios tienen menos días con registros, y en ciertos casos se observan días donde el valor de energía es visiblemente menor al esperado.

Por ejemplo, al analizar los datos desde el punto de vista de las horas de carga, se identifica que hay sitios que no alcanzan las 23 o 24 horas diarias esperadas. Esto sugiere posibles fallos en la alimentación eléctrica, cortes temporales o inconsistencias en la medición, lo que a su vez puede reflejarse como valores anómalos en el consumo energético.

Detectar estos valores atípicos (outliers) resulta fundamental porque:

- Permite mejorar la precisión de modelos futuros de predicción energética.
- Ayuda a identificar comportamientos anormales en la operación de los sitios (fallos, desconexiones, errores de medición).
- Contribuye a una mejor limpieza y calidad de los datos, especialmente en tareas que requieren series temporales consistentes.

1.1. ¿Qué se considera un outlier en este caso?

En este trabajo, cuando hablamos de un outlier nos referimos a un valor de energía diaria que no se comporta como se esperaría en condiciones normales. Es decir, cuando el consumo de energía de un sitio, en un día específico, es mucho más bajo de lo habitual.

Los sitios de telecomunicaciones están diseñados para operar casi todo el tiempo, así que su consumo diario debería mantenerse relativamente estable. Por eso, cuando un sitio registra menos energía, puede estar ocurriendo algo fuera de lo común. A veces se trata de fallas eléctricas, desconexiones temporales, problemas con el equipo de medición o incluso errores en el sistema que registra los datos.

Aunque no tenemos una lista que diga “estos son errores confirmados”, sí contamos con señales indirectas. Una de las más claras es la cantidad de horas de carga que tuvo el sitio en ese día. En muchos casos, cuando hay menos de 23 horas de carga, también se nota una caída en el valor de energía. Eso nos da una base para suponer que, en esos casos, podría haber un valor atípico.

2. Revisión de literatura

La detección de valores atípicos en series de tiempo es esencial para preservar la calidad de los datos, evitar errores en los modelos predictivos y facilitar una toma de decisiones basada en evidencia confia- ble. [Hawkins, 1980] define un outlier como una observación que se aleja tanto de las demás que sugiere haber sido generada por un mecanismo diferente. Esta distinción es clave, pues permite diferenciar entre ruido aleatorio y verdaderas anomalías que podrían indicar fallas operativas, cambios de comportamiento o errores de registro. Además, si estos valores no se corrigen o al menos se consideran en el análisis, pueden distorsionar parámetros clave como la media, la varianza o los coeficientes de modelos, haciendo que las predicciones pierdan precisión o incluso sentido [Chen and Liu, 1993]. Este enfoque ha sido fundamental para desarrollar herramientas como la función tsOutlierIdentification, disponible en R, basada en el modelo de [Chen and Liu, 1993], que identifica y corrige simultáneamente valores atípicos y parámetros del modelo para fortalecer la robustez del análisis. Además, [Gupta et al., 2014] destaca cómo la detección oportuna de estas anomalías puede ser crucial para aplicaciones sensibles al tiempo como la detección de fraudes, el monitoreo de salud o el análisis de consumo eléctrico.

2.1. Enfoques clásicos para detección de outliers

Varios autores han documentado los métodos clásicos de detección de valores atípicos, que suelen partir de suposiciones paramétricas sobre la distribución de los datos. Por ejemplo, [Chandola et al., 2009] y [Gupta et al., 2014] explican cómo se utilizan medidas como la desviación estándar, puntuaciones Z, o los residuos de modelos ARIMA para señalar observaciones fuera de lo esperado. [Weron, 2006] propone un umbral basado en la mediana móvil y desviaciones estándar, aunque reconoce que su efectividad disminuye cuando hay outliers consecutivos. Este enfoque ha sido adoptado en herramientas como la función tsoutliers() del paquete forecast en R, descrita por [Hyndman, 2021], que identifica anomalías en el componente residual de una serie tras eliminar tendencia y estacionalidad. Aunque estas técnicas son fáciles de implementar e interpretar, presentan limitaciones en presencia de patrones no lineales, estacionalidades complejas o ruido estructurado. [Chen and Liu, 1993] complementa esta visión al proponer un procedimiento secuencial para detectar y corregir distintos tipos de outliers, como los aditivos, innovacionales o los cambios de nivel, lo que permite entender no sólo cuándo hay un valor anómalo, sino cómo afecta al resto de la serie. Su enfoque iterativo y estructurado ha sido particularmente valioso para aplicaciones automatizadas que requieren robustez y adaptabilidad sin intervención manual.

2.2. Técnicas modernas y aprendizaje automático

Con el aumento en la complejidad y volumen de los datos, han surgido enfoques más sofisticados. El algoritmo RBDA propuesto por [Huang et al., 2011] evalúa la 'atipicidad' de una observación con base en su vecindario, superando métodos como LOF o COF en escenarios con densidades variables. También se han utilizado modelos probabilísticos como ARIMA bayesiano o modelos de espacio de estados, los cuales integran la detección de outliers dentro del proceso de estimación [Gupta et al., 2014, Alexandrov et al., 2019]. Por otro lado, las redes neuronales recurrentes (RNN, LSTM), autoencoders y transformers permiten detectar anomalías como errores de reconstrucción, especialmente en series multivariadas o de alta dimensionalidad [Faloutsos et al., 2019]. Además, [Aggarwal, 2017] y [Chandola et al., 2009] enfatizan la importancia de los enfoques híbridos que combinan modelos estadísticos con técnicas de machine learning para lograr detecciones más precisas y adaptables. Estas propuestas modernas permiten detectar outliers incluso cuando no son extremos en términos absolutos, pero sí lo son respecto al contexto o estructura local de la serie.

2.3. Imputación de valores faltantes y tratamiento posterior a la detección

Una vez identificados, los outliers suelen marcarse como valores faltantes para evitar su influencia negativa. Aquí entra en juego la imputación. [Abulkhair, 2023] y [GeeksforGeeks, 2023] enfatizan que imputar no es simplemente rellenar vacíos, sino una decisión analítica que puede alterar la estructura de la serie. La librería imputeTS de R [Moritz and Bartz-Beielstein, 2016] ofrece herramientas como interpolación lineal, filtro de Kalman o descomposición estacional para imputar de forma coherente. Estas técnicas ayudan a preservar la tendencia, la estacionalidad y las correlaciones temporales. [Abulkhair, 2023] también enfatiza que el tipo de mecanismo de pérdida (MCAR, MAR, MNAR) debe guiar la selección del método. En contextos donde se requiere automatización, la función tsOutlierIdentification, basada en [Chen and Liu, 1993], mejora la estimación de modelos al corregir outliers de manera conjunta con los parámetros. Es- ta herramienta no solo limpia la serie, sino que también contribuye a mejorar la estabilidad de los modelos de predicción, haciéndolos más confiables.

2.4. Predicción en escenarios inciertos y propuestas de estandarización

[Petropoulos et al., 2022] subraya que en contextos de crisis, como el COVID-19, los modelos tradicionales pueden fallar. En estos casos, métodos simples resultan más robustos por su flexibilidad y menor dependencia de supuestos. Además, defienden la necesidad de validar modelos en condiciones reales y promover una ciencia abierta, reproducible y antifrágil. [Löning et al., 2019] propone estandarizar los procesos de modelado en series de tiempo para facilitar la comparación entre modelos, reproducibilidad y aplicación en entornos reales. Su marco modular, inspirado en scikit-learn, busca promover la investigación colaborativa y el desarrollo de herramientas reutilizables. Esta propuesta resulta especialmente valiosa en un contexto donde los métodos de análisis de series temporales tienden a ser poco compatibles entre sí, dificultando su evaluación objetiva.

La literatura revisada muestra un panorama diverso de enfoques para abordar valores atípicos y faltantes en series de tiempo. Mientras los métodos clásicos ofrecen una base rápida y comprensible, las técnicas modernas permiten mayor precisión y adaptabilidad ante datos complejos. A su vez, la imputación cuidadosa y el uso de marcos estandarizados fortalecen el análisis. En conjunto, estas herramientas contribuyen a una lectura más confiable y útil de las series temporales en sectores críticos como la energía y las telecomunicaciones.

La siguiente tabla resume las principales técnicas abordadas, con énfasis en sus fortalezas y limitaciones según el tipo de enfoque.

Categoría / Método	Descripción	Propuesto por	Ventaja	Desventaja
Estadísticos básicos	Reglas simples como media ± 3, IQR, z-score o visualización (boxplot)	Estadística clásica	Fáciles de aplicar, útiles como línea base	No consideran la dinámica temporal
tsoutliers()	Función en R que detecta outliers en residuos de modelos de series	[Hyndman, 2021]	Automatizable, integración con modelos ARIMA	Menos eficaz ante estacionalidad compleja
tsOutlier	Basada en un enfoque iterativo con ARIMA para detección de varios tipos de outliers	[Chen and Liu, 1993]	Ajuste automático del modelo	Requiere validación de supuestos del modelo
Modelos probabilísticos	ARIMA, espacio de estados, modelos bayesianos; usados para detectar valores improbables	[Aggarwal, 2017], [Gupta et al., 2014]	Capturan patrones temporales y estacionales	Sensibles a mal ajuste o supuestos incorrectos
Vecindad y densidad (RBDA, LOF, COF)	Algoritmos no paramétricos que miden rareza respecto a los vecinos más cercanos	[Huang et al., 2011], [Breunig et al., 2000]	Robustez ante densidades variables, sin suposiciones fuertes	Requieren definir correctamente número de vecinos y distancia
Aprendizaje automático	Algoritmos como Isolation Forest, One-Class SVM y clustering adaptados a series con ventanas	[Gupta et al., 2014]	Escalables, no requieren distribución previa	Dependientes de la selección de hiperparámetros, lo cual puede afectar la detección
Deep Learning	Uso de LSTM, GRU, Autoencoders o Transformers para modelar series y detectar anomalías por reconstrucción	[Gupta et al., 2014], [Alexandrov et al., 2019]	Capturan relaciones no lineales y patrones complejos	Alta demanda computacional y de datos
Modelos híbridos y adaptativos	Combinan probabilísticos, ML, deep learning y reglas para ajustarse a cambios de régimen	[Alexandrov et al., 2019], literatura reciente	Flexible ante múltiples tipos de anomalías y cambios bruscos	Complejidad en implementación e interpretación
imputeTS	Librería en R para imputación de series univariadas	[Moritz and Bartz-Beielstein, 2016]	Fácil de usar, visualizaciones integradas	Limitado a series univariadas
sktime	Infraestructura en Python para modelado, detección y evaluación en series de tiempo	[Löning et al., 2019]	Modular, reproducible, comparativa entre modelos	Curva de aprendizaje técnica inicial
Modelos simples en crisis	Reglas básicas o heurísticas en contextos volátiles o con datos escasos	[Petropoulos et al., 2022]	Robustos y rápidos ante cambios abruptos	Menor precisión en condiciones normales

Cuadro 1: Comparación de métodos de detección de outliers en series de tiempo según familia, ventajas y limitaciones

Nota: Aunque `tsoutliers()` *y* `tsOutlierIdentification` *se implementan en R, la primera detecta outliers en los residuos de un modelo ajustado, mientras que la segunda los detecta y corrige durante el ajuste del modelo, haciéndola más robusta en contextos complejos.*

3. Exploración de datos

A partir de los enfoques discutidos en la literatura, se realizó un análisis exploratorio sobre la base de datos disponible. Esta contiene registros diarios por sitio de telecomunicaciones, con información asociada a la fecha, nombre del sitio, consumo energético, horas de carga y algunas variables geográficas y temporales. Aunque el conjunto original incluía datos desde 2023, el análisis se restringió al periodo comprendido entre mayo de 2024 y mayo de 2025. Esta decisión se tomó para evitar inconsistencias generadas por cambios de nombre en los sitios.

Durante este año seleccionado, se recopilaron 1.411.192 registros, correspondientes a mediciones diarias de energía y horas de carga en miles de sitios distintos. No se encontraron valores nulos en las variables principales, y se consideraron como válidas las observaciones con 23 o 24 horas de carga, ya que muchas veces las mediciones con 23 horas reflejan en realidad casi un día completo.

La variable de horas fue clave en esta etapa inicial porque permite identificar con claridad los días en que un sitio pudo haber tenido interrupciones o fallos. Al visualizar los datos, se observó que la mayoría de los registros se concentran entre 23 y 24 horas diarias, como era esperable. Sin embargo, también se identificaron registros con menos de 23 horas, e incluso algunos pocos con valores mayores a 24, lo cual no es técnicamente posible y sugiere errores de medición o consolidación.

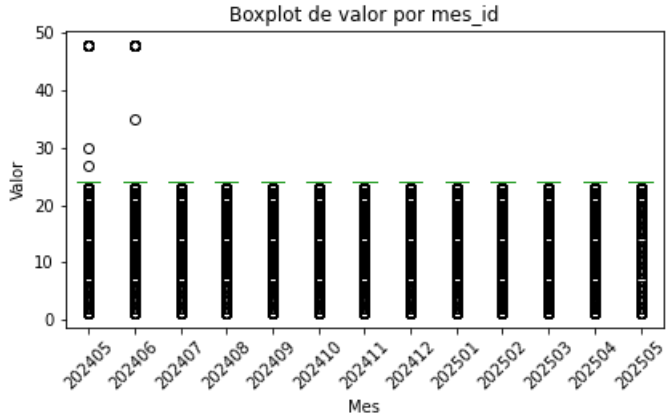


Figura 1: Distribución mensual de horas registradas por sitio

En la Figura 1, observamos un boxplot con agregación mensual que muestra cómo la mayoría de los registros se ubica dentro del rango esperado, pero también destaca la presencia de valores fuera de rango en varios momentos del año. Esta observación motivó la construcción de histogramas específicos para los extremos inferiores y superiores.

Para complementar el análisis visual de los valores atípicos, se generaron tres histogramas con distintos filtros sobre la variable de horas. Estas gráficas permiten observar con mayor detalle la distribución de los registros fuera del rango considerado habitual (23 y 24 horas).

Como muestran las Figuras 2 y 4, la mayor parte de los valores anómalos corresponde a días con menos de 23 horas, con una distribución amplia entre 0 y 22 horas. Los registros que exceden las 24 horas son más escasos, pero alcanzan cifras inusuales que refuerzan su carácter claramente atípico. La concentración de estos casos en meses puntuales sugiere que no se trata de fluctuaciones normales, sino de errores de registro o eventos operativos excepcionales.

Aunque este primer análisis se centró en la variable de horas —por su estructura más acotada y fácil de

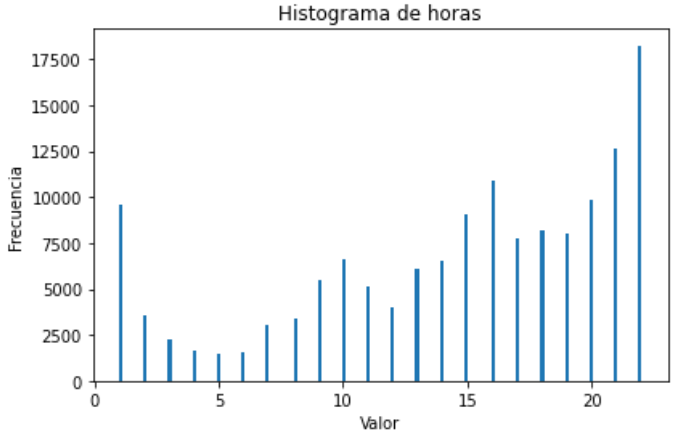


Figura 2: Histograma de horas menores a 23.



Figura 3: Histograma de horas menores a 23 y mayores de 24



Figura 4: Histograma de horas mayores a 24.

interpretar—, la detección formal de valores atípicos se realizará sobre la variable de energía consumida. Esta decisión responde a dos razones principales. En primer lugar, porque la energía refleja con mayor precisión el comportamiento técnico del sitio, al incorporar tanto la unidad de procesamiento como la unidad de radio. Y en segundo lugar, porque la energía es la variable que podría afectar directamente la calidad de modelos predictivos, diagnósticos operativos o decisiones sobre mantenimiento.

Finalmente, como no todos los sitios tienen la misma cantidad de registros outliners tal como lo mencionamos anteriormente, se realiza una tabla que permita observar ligeramente como son estos dos por sitio. Como estos datos son privados y compromete la etica de la compañia, solo se muestran esos 5 para ilustrar

cómo se pueden ver.

Además, dado que los niveles de consumo energético pueden variar considerablemente entre sitios —por diferencias técnicas, condiciones ambientales o demandas de uso—, no resulta adecuado aplicar umbrales globales. En lugar de eso, se optó por una estrategia que evalúe los registros en función del comportamiento histórico de cada sitio, con el objetivo de identificar valores que, sin ser extremos en términos absolutos, se desvíen del patrón que normalmente presenta ese lugar.

Con este marco de análisis definido, la siguiente sección presenta los modelos seleccionados para implementar la detección automática de outliers en las series energéticas por sitio.

4. Modelos Utilizados

Una vez realizada la exploración de los datos y definido que los outliers deben identificarse en relación con el comportamiento específico de cada sitio, se procedió a la elección de los modelos que permitirían detectar estos valores de forma automatizada. Para ello, se seleccionaron dos enfoques distintos, que abordan el problema desde perspectivas complementarias: Isolation Forest, un algoritmo de aprendizaje automático, y Prophet, un modelo estadístico de series temporales.

Ambos modelos fueron aplicados de forma independiente a cada sitio, utilizando únicamente la serie diaria de energía consumida. La decisión de comparar estos dos métodos se basó en su capacidad para detectar anomalías desde ángulos diferentes: uno enfocado en la forma general de los datos, y otro en su evolución en el tiempo. Esto permite obtener una visión más completa y robusta del comportamiento anómalo.

4.1. Isolation Forest

Isolation Forest es un algoritmo no supervisado diseñado específicamente para detectar anomalías. Su funcionamiento se basa en una idea intuitiva: los valores atípicos son diferentes al resto, por lo que pueden "aislarse" con mayor facilidad. Para hacerlo, el modelo construye múltiples árboles de decisión que dividen aleatoriamente los datos, y mide cuántas divisiones se requieren para aislar cada punto. Si un valor se separa en muy pocos pasos, es probable que se trate de un outlier.

Una de las principales ventajas de este método es que no necesita suponer ninguna estructura temporal ni conocer cómo se comportan normalmente los datos, lo que lo hace útil para series con comportamientos variables o difíciles de modelar. Además, es eficiente en términos computacionales, lo que permitió aplicarlo individualmente a cada sitio, incluso con una base de datos extensa como la utilizada en este estudio.

En este caso, el modelo se entrenó con los valores de energía diaria por sitio, sin incluir ninguna otra variable. El propio algoritmo estimó qué tan anómalo era cada registro, y a partir de ese puntaje se identificaron los valores atípicos. Este enfoque resulta especialmente útil cuando se quiere una primera aproximación rápida, flexible y sin necesidad de hacer suposiciones fuertes sobre los datos.

4.2. Prophet

El segundo modelo evaluado fue Prophet, una herramienta estadística desarrollada para modelar series de tiempo que presentan estacionalidades, cambios de tendencia y comportamientos complejos. Aunque Prophet suele utilizarse para realizar predicciones, en este trabajo se empleó con un propósito diferente.

¿Cómo funciona? Prophet descompone la serie en tres partes: tendencia general, estacionalidad y posibles cambios abruptos. Una vez ajustado el modelo, se calcula la diferencia entre lo que el modelo espera y lo que realmente ocurrió (los residuos). Si esa diferencia es muy grande —es decir, si el valor real cae fuera del intervalo de confianza del 95 %—, entonces se marca como posible outlier.

Este enfoque tiene varias ventajas. Primero, tiene en cuenta el contexto temporal: no se trata solo de si un valor es alto o bajo en términos absolutos, sino de si tiene sentido en ese momento específico. Segundo, permite descomponer la serie y entender mejor por qué un valor es considerado anómalo. Y tercero, es flexible y automatizable, lo cual lo hace adecuado para analizar cientos de sitios con comportamientos diferentes.

En este caso, Prophet se aplicó por separado a cada sitio, sin incorporar variables externas. Esto permite enfocarse únicamente en el patrón interno de consumo de cada uno. Al identificar como outliers aquellos valores fuera del 95 % de confianza, se logró un equilibrio entre sensibilidad y precisión, evitando tanto los falsos positivos como los casos ignorados por error.

5. Resultados

Después de aplicar los dos modelos seleccionados, se analizaron los resultados para entender cómo identifican los valores atípicos y qué tan diferente es el enfoque de cada uno. Para ilustrar este análisis, observaremos cómo se comportan los modelos Isolation Forest y Prophet en dos sitios específicos. La única condición para seleccionar estos sitios fue que estuvieran activos durante el año 2025. La elección se hizo de forma aleatoria, sin seguir ningún criterio técnico o geográfico particular. Además, solo se muestran dos sitios como ejemplo por dos razones: la primera, para proteger la confidencialidad de la información sensible de la empresa; y la segunda, porque incluir más ejemplos no aportaba nueva información relevante al análisis principal.

5.1. ARA0001

En las siguientes dos figuras se muestran los resultados de detección de outliers para el sitio ARA0001. La primera corresponde al modelo Isolation Forest y la segunda al modelo Prophet.

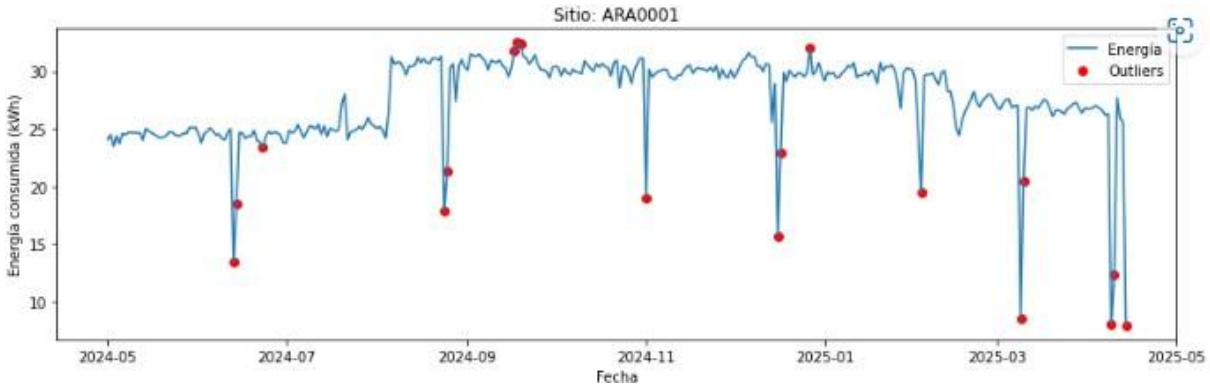


Figura 5: Sitio ARA - Isolation

En el sitio ARA0001 se observa un comportamiento bastante marcado: a lo largo del año, hay varios días en los que el consumo de energía cae de forma abrupta. Estos días están señalados con puntos rojos, que representan los outliers detectados por cada modelo.

En el primer gráfico, que corresponde al modelo Isolation Forest, la línea azul muestra el consumo de energía diario, y los outliers se destacan como puntos rojos sobre la misma línea. La mayoría de estos outliers aparecen en momentos de caídas pronunciadas en la energía, pero también hay uno o dos valores altos marcados como atípicos. Esto se debe a que el modelo identifica valores que se alejan mucho del patrón general, sin tener en cuenta si ese valor tiene sentido en un momento específico.

En el segundo gráfico, generado con Prophet, se muestran varios elementos que ayudan a entender mejor el comportamiento del sitio: la línea negra representa los valores reales de energía registrados cada

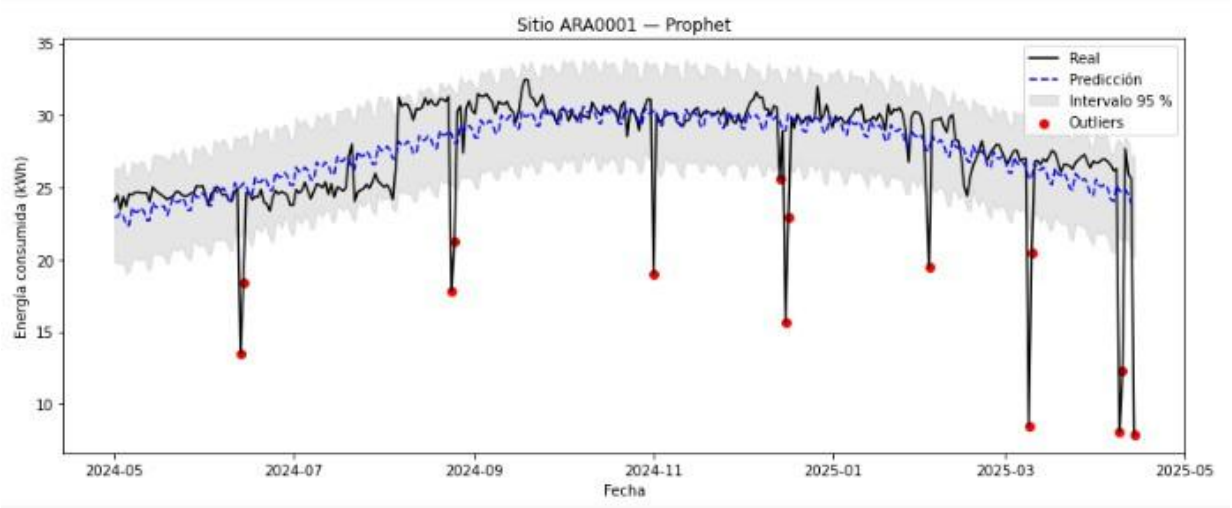


Figura 6: Sitio ARA - Prophet

día, mientras que la línea azul punteada es la predicción que hace el modelo sobre cómo debería comportarse esa energía en condiciones normales. Alrededor de esa predicción aparece una franja gris, que es el intervalo de confianza del 95 %, es decir, un rango donde se espera que caigan la mayoría de los valores si todo está funcionando como de costumbre. Cuando un valor real se sale de esa banda, el modelo lo marca como outlier, y por eso vemos puntos rojos justo en esos días. Esos puntos indican momentos en los que el comportamiento del sitio fue muy diferente a lo esperado, y por eso llaman la atención dentro del análisis.

5.2. ARM0011

En el sitio ARM0011 también se identificaron varios outliers a lo largo del año, aunque visualmente el comportamiento general parece mucho más estable que en el sitio anterior.

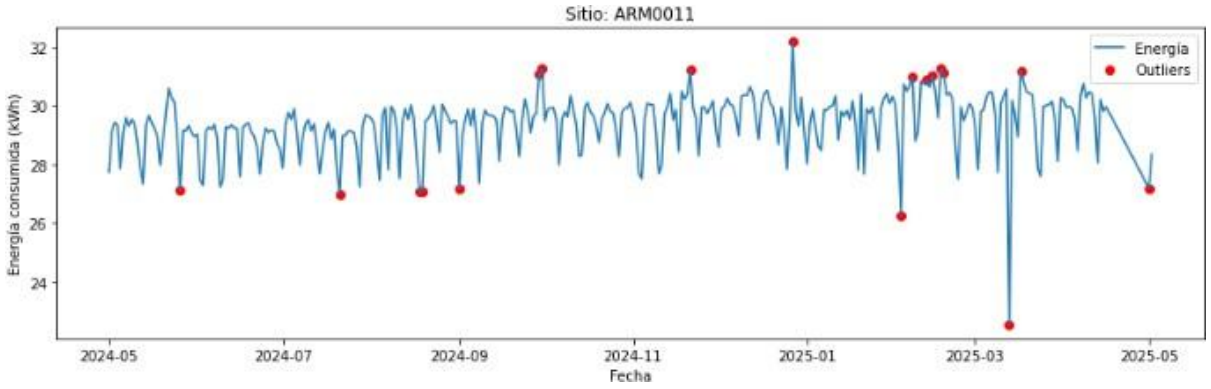


Figura 7: ARM0011 - Isolation

En el sitio anterior, los outliers hacia arriba solo se veían en el gráfico de Isolation Forest; en cambio, en este caso aparecen en ambos modelos, incluyendo Prophet, lo cual resulta llamativo. Las caídas suelen ser más fáciles de interpretar, ya que pueden estar asociadas a fallos eléctricos o desconexiones temporales. Por su parte, los aumentos inesperados no siempre tienen una causa evidente y, en algunos casos, podrían estar relacionados con errores de medición u otros comportamientos poco comunes.
Un detalle que llama la atención en el gráfico de Prophet es que uno de los puntos marcados como outlier está dentro de la franja gris del intervalo de confianza. Aunque no es lo más común, esto puede pasar por varias razones: tal vez el valor se aleja lo suficiente de la predicción puntual, o hubo un cambio de tendencia que el modelo no logró capturar del todo. También podría deberse simplemente a un ajuste imperfecto del modelo. Eso hace que el modelo lo marque como un comportamiento inusual, aunque visualmente no

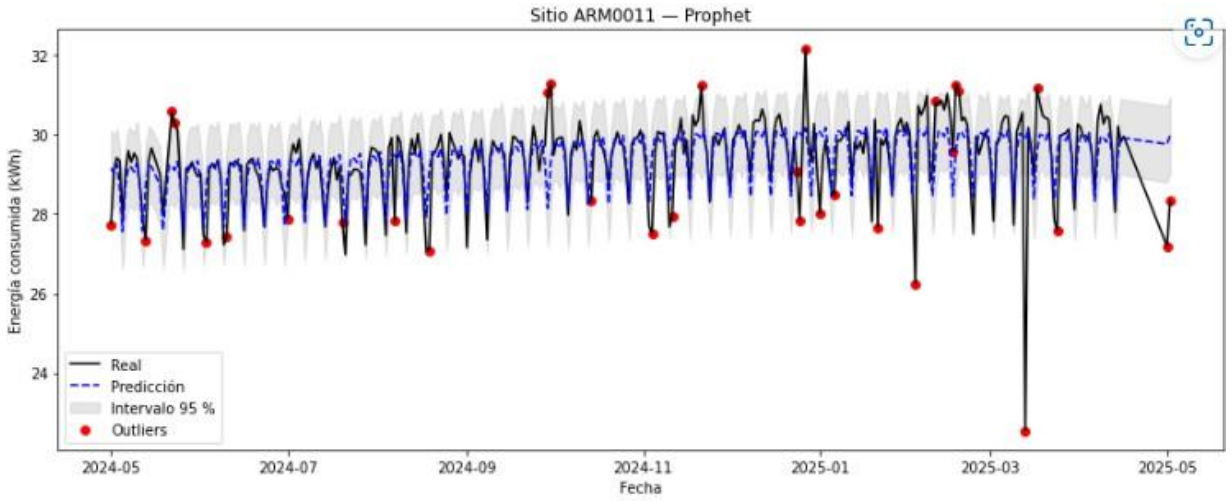


Figura 8: ARM0011 - Prophet

parezca tan extremo.

Aunque los modelos marcan estas observaciones como posibles outliers, no necesariamente se trata de errores en los datos: en muchos casos, podrían estar reflejando eventos reales.
Teniendo en cuenta que el sitio ARA0001 está ubicado en Arauca, es posible que algunas de esas caídas se deban a interrupciones en el servicio eléctrico. Esta región ha presentado históricamente una mayor cantidad de cortes, ya sea por mantenimientos programados o por condiciones de infraestructura menos estables. De hecho, empresas como ENELAR han reportado suspensiones frecuentes por trabajos en la red, especialmente en municipios como Saravena o Tame. En esos casos, el sitio no necesariamente está fallando, sino que simplemente no tuvo suministro por varias horas ese día.

Por otro lado, el sitio ARM0011 corresponde a Armenia, una ciudad con una red eléctrica más consolidada, según reportes de la empresa EDEQ. En este caso, es coherente que el consumo energético se vea más continuo y presente menos interrupciones reales. Sin embargo, al comparar ambos gráficos del modelo Prophet, se observa un detalle interesante: en ARM0011 aparecen más caídas marcadas como atípicas que en ARA0001, pero estas suelen ser más suaves. En cambio, en ARA0001 hay menos caídas, pero son mucho más pronunciadas.
Esto sugiere que en Armenia puede haber más variaciones pequeñas o inusuales en el patrón diario, mientras que en Arauca, aunque las caídas son menos frecuentes, cuando ocurren reflejan eventos más extremos. Por eso, más allá de contar cuántos outliers aparecen, también es importante observar su magnitud y contexto para entender mejor el comportamiento de cada sitio.

6. Comparación de modelos

Ahora, podemos proseguir con la comparación de los modelos. Surge la pregunta natural: ¿cuál deberíamos usar? En algunos casos, esta decisión puede apoyarse en métricas específicas como precisión, recall o F1-score, que permiten evaluar qué tan bien detecta cada modelo los outliers. Sin embargo, en este estudio no contamos con datos etiquetados, es decir, no sabemos de antemano cuáles valores son realmente atípicos y cuáles no. Esta ausencia de "verdad conocida" limita la posibilidad de aplicar esas métricas de evaluación tradicionales.
Por eso, para esta comparación se tuvo en cuenta el comportamiento visual de cada modelo (es decir, cuántos puntos marca como outliers), también se consideraron aspectos como el tiempo de ejecución, la facilidad de uso, si requieren o no definir parámetros adicionales, qué tan intuitivos son sus resultados, qué tan bien detectan caídas abruptas. Todos estos elementos se resumen en el siguiente cuadro comparativo.

Criterio	Prophet	Isolation Forest
Considera la estructura temporal	Sí	No
Visualización e interpretación	Clara y explicativa	Poco interpretable
Requiere parametrización	Algunos parámetros	Muy pocos o ninguno
Tiempo de ejecución	Más lento	Más rápido
Sensible a picos altos	Menos sensible	Más propenso
Facilidad de uso	Intermedia	Alta
Explicabilidad del resultado	Alta	Baja

Cuadro 2: Comparación cualitativa entre Prophet e Isolation Forest

Si Isolation está hecho para detectar outliers, ¿por qué parece que Prophet es mejor?
A simple vista puede parecer irónico que Prophet, un modelo que no fue diseñado exclusivamente para detectar outliers, ofrezca resultados que en muchos casos parecen más útiles o más fáciles de interpretar que los de Isolation Forest, que sí está hecho para ese propósito. Pero esto tiene sentido si se considera que Prophet modela directamente la serie temporal, teniendo en cuenta la tendencia, la estacionalidad y los patrones esperados del comportamiento, mientras que Isolation Forest se basa únicamente en la distribución general de los datos, sin mirar el orden ni la lógica temporal. En contextos como este, donde el tiempo juega un papel clave, Prophet puede ofrecer una ventaja importante: no solo detecta lo inusual, sino que permite entender por qué lo considera así, lo cual es muy útil en entornos operativos. Aun así, Isolation Forest sigue siendo valioso como herramienta complementaria, especialmente por su rapidez, bajo requerimiento de configuración y capacidad para detectar desviaciones más genéricas.

7. Conclusiones

Este trabajo permitió explorar cómo se comportan dos enfoques distintos para detectar outliers en series temporales, especificamente en el consumo energético, aunque podría replicarse en otro tipo de datos. Aunque no se contaba con datos etiquetados para saber con certeza qué puntos eran realmente atípicos, el análisis visual y comparativo dio luces sobre el tipo de eventos que cada modelo tiende a marcar.

Algo que quedó claro es que la interpretación de los outliers no depende solo del modelo, sino también del contexto. Algunos puntos pueden parecer errores, pero al revisar aspectos como la región o el comportamiento general del sitio, es posible que estén reflejando eventos reales, como interrupciones en el servicio. Por eso, más que buscar cuál modelo es “mejor”, tiene más sentido usarlos como herramientas complementarias que permiten mirar los datos desde diferentes ángulos.

También se notó que, aunque Prophet no fue pensado directamente para detectar outliers, funciona bastante bien para este propósito en series temporales, ya que muestra lo que esperaba que pasara, su predicción puntual y el rango de confianza. Eso ayuda mucho a interpretar por qué un punto se considera inusual. Isolation Forest, en cambio, ofrece una detección más rápida y general, pero menos explicable. El uso de estos dos enfoques permitió detectar patrones que podrían ser relevantes para entender mejor lo que pasa en los sitios incluso sin etiquetas.

8. Limitaciones y Recomendaciones

Como todo trabajo exploratorio, este análisis tiene limitaciones que es importante reconocer, pero también deja varias ideas que podrían orientar mejoras en el futuro. Más que verlas como obstáculos, estas limitaciones ayudan a entender el alcance real de lo logrado y abren la posibilidad de seguir afinando el enfoque, especialmente si se quiere llevar a un contexto más amplio o aplicado.

Una de las principales limitaciones fue no contar con datos etiquetados que indicaran cuáles puntos eran realmente atípicos. Por eso, la comparación entre modelos se basó en la visualización de los resulta- dos. Una posible mejora sería validar manualmente algunos outliers detectados, cruzándolos con registros operativos o eventos conocidos. Esto permitiría aplicar métricas más precisas y ajustar los modelos con mayor confianza.

Finalmente, otra limitación fue que la cantidad de variables usadas, ya que solo se usaron datos de consumo energético. Incluir variables externas como clima, mantenimientos programados o tipo de tecnología del sitio podría ayudar a explicar mejor ciertos comportamientos marcados como atípicos y reducir la cantidad de falsos positivos.

Referencias

[Abulkhair, 2023] Abulkhair, A. (2023). Data imputation demystified: Time series data. *Medium*. Recuperado de Medium.

[Aggarwal, 2017] Aggarwal, C. C. (2017). *Outlier Analysis*. Springer International Publishing.

[Alexandrov et al., 2019] Alexandrov, A., Benidis, K., Bohlke-Schneider, M., Flunkert, V., Gasthaus, J., Januschowski, T., Maddix, D. C., Rangapuram, S., Salinas, D., Schulz, J., Stella, L., Türkmen, A. C., and Wang, Y. (2019). Gluonts: Probabilistic time series models in python.

[Breunig et al., 2000] Breunig, M. M., Kriegel, H.-P., Ng, R. T., and Sander, J. (2000). Lof: identifying density-based local outliers. In *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*, SIGMOD '00, page 93–104, New York, NY, USA. Association for Computing Machinery.

[Chandola et al., 2009] Chandola, V., Banerjee, A., and Kumar, V. (2009). Anomaly detection: A survey. *ACM Comput. Surv.*

[Chen and Liu, 1993] Chen, C.-Z. and Liu, L.-M. (1993). Joint estimation of model parameters and outlier effects in time series. *Journal of the American Statistical Association*, 88(421):284–297.

[Faloutsos et al., 2019] Faloutsos, C., Gasthaus, J., Januschowski, T., and Wang, Y. (2019). Classical and contemporary approaches to big time series forecasting. In *Proceedings of the 2019 International Conference on Management of Data (SIGMOD)*, pages 2042–2047. ACM.

[GeeksforGeeks, 2023] GeeksforGeeks (2023). How to deal with missing values in a timeseries in python? Recuperado el 2 de junio de 2025.

[Gupta et al., 2014] Gupta, M., Gao, J., Aggarwal, C. C., and Han, J. (2014). Outlier detection for temporal data: A survey. *IEEE Transactions on Knowledge and Data Engineering*, 26(9):2250–2267.

[Hawkins, 1980] Hawkins, D. M. (1980). *Identification of Outliers*. Springer Netherlands, Dordrecht, The Netherlands.

[Huang et al., 2011] Huang, H., Mehrotra, K., and Mohan, C. (2011). Rank-based outlier detection. *Journal of Statistical Computation and Simulation*, iFirst.

[Hyndman, 2021] Hyndman, R. J. (2021). Detecting outliers in time series data. https://robjhyndman.com/hyndsight/tsoutliers/. Blog post.

[Löning et al., 2019] Löning, M., Bagnall, A., Ganesh, S., Kazakov, V., Lines, J., and Kiraly, F. J. (2019). Time series forecasting with sktime: A unified interface for machine learning with time series. *arXiv preprint arXiv:1909.07872*.

[Moritz and Bartz-Beielstein, 2016] Moritz, S. and Bartz-Beielstein, T. (2016). imputets: Time series missing value imputation in r. *The R Journal*, 9(1):207–218.

[Petropoulos et al., 2022] Petropoulos, F., Makridakis, S., Hyndman, R. J., and Spiliotis, E. (2022). Forecasting in the presence of exceptional events: lessons from the covid-19 pandemic. *International Journal of Forecasting*, 38(2):505–519.

[Weron, 2006] Weron, R. (2006). *Modeling and Forecasting Electricity Loads*, chapter 3, pages 67–100. John Wiley Sons, Ltd.