



UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE INGENIERÍA



Identificación y desagregación de consumo eléctrico por medio de inteligencia artificial

TESIS PRESENTADA A LA FACULTAD DE INGENIERÍA DE LA
UNIVERSIDAD DE LA REPÚBLICA POR

Camilo Mariño

EN CUMPLIMIENTO PARCIAL DE LOS REQUERIMIENTOS
PARA LA OBTENCIÓN DEL TÍTULO DE
MAGISTER EN INGENIERÍA ELÉCTRICA.

DIRECTORES DE TESIS

Alicia Fernández Universidad de la República
Matías Di Martino Duke University

TRIBUNAL

Ruben Chaer Universidad de la República
Martin Rocamora Universidad de la República
Carlos León de Mora Universidad de Sevilla

DIRECTOR ACADÉMICO

Alicia Fernández Universidad de la República

Montevideo
viernes 21 abril, 2023

Identificación y desagregación de consumo eléctrico por medio de inteligencia artificial, Camilo Mariño.

ISSN 1688-2806

Esta tesis fue preparada en L^AT_EX usando la clase iietesis (v1.1).

Contiene un total de 167 páginas.

Compilada el viernes 21 abril, 2023.

<http://iie.fing.edu.uy/>

Si supiese qué es lo que estoy haciendo, no lo llamaría investigación, ¿verdad?

ALBERT EINSTEIN

Agradecimientos

Primero que nada, un enorme agradecimiento a mis tutores. A Alicia por creer en mí, apostar a mi capacidad y por brindarme tu apoyo incondicional para lograr este objetivo. A vos Matías, por haber estado presente más allá de la distancia y por tus valiosos aportes que enriquecieron este trabajo.

Un reconocimiento especial al grupo técnico de colaboración compuesto por la Facultad de Ingeniería y la empresa UTE. Las ideas e información surgidas de las reuniones que mantuvimos juntos han sido invaluable para este proyecto. En sentido, fueron valiosísimos los aportes de Fernando Santomauro, Gaston Hernandez, Gustavo Alvez, Liliana Corna, Santiago Garabedian, Sebastian Alpuy, Alvaro Gomez, Elías Masquil, Guillermo Cossio y Pablo Massafferro.

También quiero valorar a mis compañeras y compañeros del IIE, quienes han sido clave en mi formación, tanto técnica como humana. A Lucas por ser el compañero de batalla en pleno verano durante esas interminables tardes de documentación en el IIE. A Romina por revisar el trabajo con detalle y brindarme sugerencias. Y por supuesto no puedo olvidarme de Emiliano, Elías, Diego, Guillermo, Leopoldo y Martín.

Por supuesto, mi familia ha sido el pilar fundamental que ha permitido y fomentado mi formación. En especial, gracias a mi viejo por leer y sugerir mejoras al documento desde otra perspectiva, a mi madre por estar siempre presente, a mis hermanos y a mi abuela.

Finalmente, expresar mi más sincero agradecimiento a la UdelaR por abrirme sus puertas y brindarme una educación de calidad. En este marco también jugaron un papel fundamental la CAP y la CSIC por las becas recibidas.

Resumen

La gestión eficiente del consumo de energía eléctrica ha cobrado más importancia en las últimas décadas por su impacto en el medio ambiente y la economía. Con el aumento de la adopción de fuentes de energía renovables y la creciente preocupación por el cambio climático, las empresas distribuidoras de energía eléctrica buscan constantemente nuevas metodologías para influir en la demanda de energía eléctrica sin afectar el confort del usuario.

Una técnica comúnmente utilizada para influir en los patrones de consumo es la generación de incentivos a través de tarifas bonificadas para aquellos usuarios que siguen patrones de consumo eficientes. Para aplicar esta técnica es esencial contar con mecanismos de monitoreo de consumo.

El presente trabajo aborda el problema de monitoreo de consumo eléctrico mediante técnicas de aprendizaje supervisado con redes neuronales profundas, enfocándose en: i) la identificación del tipo de electrodoméstico a partir de una curva de consumo desagregada y ii) la desagregación del consumo de electrodomésticos a partir de una curva de consumo agregada. Ambos enfoques de monitoreo se realizan sobre datos a muy bajas frecuencias, desde una muestra por minuto hasta una muestra cada 15 minutos. Complementariamente, se pone foco en electrodomésticos poco estudiados en la literatura, como los termotanques que son ampliamente utilizados en Uruguay y los vehículos eléctricos, cuyo uso está en fase expansiva y presentan un consumo elevado.

En Uruguay, durante los últimos años, la Administración Nacional de Usinas y Transmisiones Eléctricas del Estado (UTE) ha comenzado a utilizar medidores inteligentes capaces de recolectar datos de consumo eléctrico de los clientes en intervalos de 15 minutos, así como ha proporcionado medidores intrusivos a grupos de usuarios para monitorear el consumo de termotanques cada 1 minuto. En este trabajo se investigan técnicas de aprendizaje profundo, las cuales son entrenadas y evaluadas sobre una amplia cantidad de datos del sistema eléctrico uruguayo.

Por otro lado, en el presente estudio se generan y preparan bases de datos, para ser compartidas de forma libre y en un formato estándar, facilitando así su acceso por parte de la comunidad científica.

Finalmente, la implementación de los modelos dio lugar a transferencias tecnológicas entre la Facultad de Ingeniería (FING) y UTE, lo que posibilita que UTE utilice los algoritmos de aprendizaje automático desarrollados en aplicaciones específicas de su interés, evidenciando el impacto de este trabajo en el ámbito productivo.

Abstract

Efficient management of electrical energy consumption has gained increasing importance in recent decades due to its impact on the environment and the economy. With the growing adoption of renewable energy sources and heightened concern for climate change, electric power distribution companies constantly seek new methodologies to influence electricity demand without affecting user comfort.

A common technique used to influence consumption patterns is the generation of incentives through discounted rates for users who follow efficient consumption patterns. Therefore, it is essential to have consumption monitoring mechanisms in place to apply this technique.

This study addresses the problem of electricity consumption monitoring using supervised learning techniques with deep neural networks, focusing on: i) the identification of appliances from a disaggregated consumption curve and ii) the disaggregation of appliances from an aggregated consumption curve. Both monitoring approaches are performed on very low-frequency data, ranging from one sample per minute to one sample every 15 minutes. Additionally, emphasis is placed on under-studied appliances in the literature, such as water heaters widely used in Uruguay and electric vehicles, whose usage is expanding and present high consumption levels.

In Uruguay, over recent years, the Administración Nacional de Usinas y Transmisiones Eléctricas del Estado (UTE) has begun using intelligent meters capable of collecting customer electricity consumption data at 15-minute intervals and providing intrusive meters to user groups for monitoring water heater consumption every 1 minute. This work investigates deep learning techniques, which are trained and evaluated on a large amount of data from the Uruguayan electrical system.

Furthermore, this study generates and prepares databases to be freely shared in a standard format, thus facilitating their access by the scientific community.

Finally, implementing the models led to technology transfers between the Facultad de Ingeniería (FING) and UTE, enabling UTE to use the developed machine learning algorithms in specific applications of their interest, thus demonstrating the impact of this work on the productive sector.

Tabla de contenidos

Agradecimientos	III
Resumen	V
Abstract	VII
1. Introducción	1
1.1. Motivación	1
1.2. Descripción del problema	3
1.2.1. Monitoreo de cargas	3
1.2.2. Intervalo de muestreo	5
1.2.3. Electrodomésticos de interés	6
1.3. Contexto	7
1.4. Objetivos	7
1.5. Contribuciones	8
1.6. Estructura del documento	9
2. Estado del arte	11
2.1. NILM: Desagregación de consumo	11
2.1.1. Enfoques a baja frecuencia	12
2.1.2. Enfoques sobre termotanques y vehículos eléctricos a muy baja frecuencia	14
2.2. ILM: Identificación de electrodomésticos	16
3. Generación y preparación de bases de datos	19
3.1. Introducción	19
3.2. Bases de datos públicas	21
3.3. Bases de datos propias	24
3.3.1. Base de datos de termotanques (UTEFING_TT)	25
3.3.2. Base de datos de vehículos eléctricos (UTEFING_VE)	26
3.3.3. Base de datos de aires acondicionados (UTEFING_AA)	27
3.3.4. Base de datos NILM-UY	28
3.4. Comparativa de bases de datos	29
3.5. Formato de almacenamiento y lectura NILMTK-HDF	29
3.6. Convertidores NILMTK-HDF implementados	31
3.6.1. GREEND	32

Tabla de contenidos

3.6.2.	RAE	32
3.6.3.	ENERTALK	32
3.6.4.	NILM-UY	32
3.6.5.	GeLap	33
3.6.6.	MORED	33
3.6.7.	UTEFING_TT, UTEFING_VE y UTEFING_AA	33
3.7.	Descripción de patrones de consumo de electrodomésticos	33
3.7.1.	Categorización en tiempo corto	34
3.7.2.	Categorización en tiempo largo	36
3.7.3.	Patrones de consumo del termotanque	36
3.7.4.	Patrones de consumo del vehículo eléctrico	39
3.7.5.	Patrones a distinta escala temporal	39
4.	Identificación intrusiva del tipo de electrodoméstico	41
4.1.	Definición del problema	41
4.2.	DL-ILM: Deep Learning para ILM	41
4.2.1.	Datos	42
4.2.2.	Algoritmos de clasificación	47
4.3.	Métricas	49
4.3.1.	Métricas de clasificación binarias	49
4.3.2.	Métricas de clasificación multiclase	50
4.4.	Procedimiento de entrenamiento	51
4.5.	Hiperpárametros	51
4.6.	Resultados	51
4.6.1.	Resultados de clasificación multiclase	52
4.6.2.	Resultados de clasificación binaria	54
4.6.3.	Resultados al variar la tasa de muestreo	55
5.	Desagregación no intrusiva de electrodomésticos	57
5.1.	Definición del problema	57
5.2.	DL-NILM: Deep Learning para NILM	58
5.2.1.	Datos	58
5.2.2.	Propuestas de modelos para calcular f^{-1}	62
5.2.3.	Post-procesamiento	64
5.3.	Función de pérdida	65
5.4.	Métricas	65
5.4.1.	Métricas de estado binario	65
5.4.2.	Métricas de regresión	67
5.5.	Entrenamiento e Hiperparámetros	67
5.6.	Resultados	68
5.6.1.	Resultados sobre termotanques a tasa de 15 minutos	68
5.6.2.	Resultados sobre vehículos eléctricos a tasa de 15 minutos	73
5.6.3.	Resultados sobre termotanques a tasa de 1 minuto	77
5.7.	Comparación con otros trabajos	82

6. Puesta en producción y aplicaciones	85
6.1. Identificación de electrodomésticos sobre clientes de UTE	85
6.2. Desagregación de consumo de una subestación de UTE	87
6.3. Estimación de la facturación mensual correspondiente a un electrodoméstico	88
6.4. Determinar presencia de un termotanque	91
6.5. Otras aplicaciones	92
7. Conclusiones	95
A. Arquitecturas de redes neuronales	97
A.1. Arquitecturas de identificación	97
A.1.1. MLP	97
A.1.2. RNN	98
A.1.3. LSTM	100
A.1.4. FCN	101
A.1.5. ResNet	102
A.1.6. InceptionTime	103
A.1.7. XCM	104
A.2. Arquitecturas de desagregación	104
A.2.1. Denoising Autoencoder (DAE)	104
A.2.2. Fully Convolutional Denoising Autoencoder	105
A.2.3. BiLSTM	106
A.2.4. Seq2Seq	107
A.2.5. ResNet	107
A.2.6. InceptionTime	108
A.2.7. Mean	109
B. Enfoques alternativos de desagregación	111
B.1. Inclusión del clasificador en la función de pérdida	111
B.2. Inclusión de una función de pérdida por estados	112
C. NMF aplicado a NILM	113
C.1. Modelado del problema	113
C.1.1. Enfoque básico	113
C.1.2. Enfoque con restricción	114
C.1.3. Enfoque con regularización L-1	114
C.1.4. Enfoque con regularización L-2	114
C.1.5. Enfoque con regularización Elastic Net	114
C.1.6. Enfoque con regularización Sum-to-k	115
C.1.7. Generalización	116
C.2. Supuestos y Limitaciones	116
C.3. Métodos de Optimización	116
C.3.1. NNLS	116
C.3.2. PGD	118
C.3.3. A-PGD	119

Tabla de contenidos

C.3.4. Comparativa	119
C.4. Experimentos	120
C.4.1. Base de datos: AMPds	120
C.4.2. Métricas de desempeño	122
C.4.3. Resultados	122
C.4.4. Resultados visuales	126
C.5. Conclusiones	130
Referencias	133
Índice de tablas	147
Índice de figuras	148

Capítulo 1

Introducción

1.1. Motivación

El consumo de energía eléctrica a nivel mundial ha crecido a un ritmo constante en los últimos años y se espera que se mantenga la tendencia al alza. De hecho, en el año 2022 se registró el mayor consumo histórico de energía eléctrica y se proyecta un aumento promedio anual del 6 % según la Energy Information Administration (EIA) ¹. En particular, el consumo energético en Uruguay ha experimentado un crecimiento constante en las últimas décadas. Según la información del Catálogo de Datos Abiertos del gobierno uruguayo, el consumo en el país aumentó en un 15 % en los últimos cinco años y en un 72 % en los últimos veinte, como se aprecia en la Figura 1.1.

A nivel mundial, la adopción de energías eólica y solar se ha acelerado, siendo estas fuentes energéticas firmes a escalas mensuales pero con variabilidades significativas en términos de horas. Por tanto, para la operación eficiente de los sistemas eléctricos, se requieren elementos de control que permitan seguir las fluctuaciones de los recursos solar y eólico. Además, la incorporación creciente de inteligencia a la red, como las redes de comunicación que facilitan el envío de señales hasta los consumidores, resalta la importancia de identificar aquellas demandas que puedan ser gestionadas para mantener el equilibrio entre oferta y demanda. La implementación de demandas con respuesta puede ser un factor clave en el camino hacia la descarbonización de los sistemas eléctricos, evitando o retrasando la necesidad de construir nuevas centrales de generación basadas en combustibles fósiles.

Resulta entonces crucial establecer incentivos que permitan adecuar la generación de energía a la demanda, teniendo en cuenta las implicancias económicas y ambientales que esto conlleva. La monitorización y análisis de los patrones de consumo eléctrico en los hogares se tornan fundamentales tanto para las empresas encargadas de la generación y distribución de energía, como para los usuarios. La capacidad de estimar el consumo eléctrico en las viviendas, desglosado por uso, constituye información vital para alcanzar dichos objetivos.

Además, monitorizar el consumo por electrodoméstico le permite a las em-

¹<https://www.eia.gov/>

Capítulo 1. Introducción

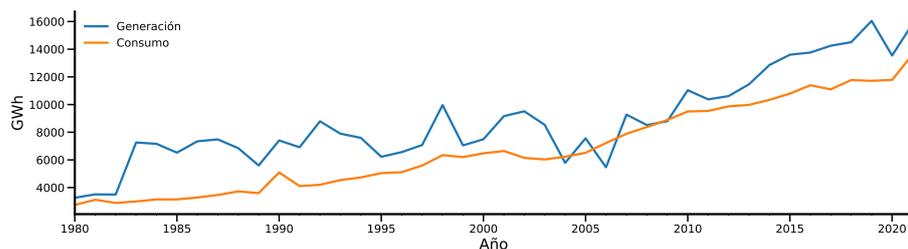


Figura 1.1: Serie histórica de generación y consumo de energía eléctrica en Uruguay. Datos extraídos del Catálogo de Datos Abiertos del Gobierno Uruguayo (<https://catalogodatos.gub.uy/>).



Figura 1.2: Izquierda: Sonoff modelo IM160810001. Derecha: TI001-MC.

presas de generación y distribución de energía proporcionar datos valiosos a los clientes sobre su consumo de energía, incluyendo información sobre el rendimiento de los electrodomésticos, la detección de posibles fallas en estos y el suministro de sugerencias para optimizar el consumo de energía. Permite también a los usuarios identificar los electrodomésticos y dispositivos que más consumen energía en su hogar, tomar medidas para reducir su consumo y ahorrar en sus facturas de electricidad.

Uno de los incentivos más comunes para ajustar la generación a la demanda es mediante planes de tarifas diferenciadas según franjas horarias. Sin embargo, con el uso de técnicas de monitorización de consumo, es posible considerar otro tipo de planes enfocados en el uso específico de la energía en el hogar. Por ejemplo, se podrían establecer tarifas diferenciadas para el uso de ciertos electrodomésticos de alta potencia como termotanques o vehículos eléctricos. La empresa UTE ya ha comenzado con estas prácticas para influir en la demanda de los usuarios, primero colocando medidores como los de la Figura 1.2 que les permite a UTE comandar al termotanque de forma remota. Se brinda también incentivos económicos² por cargar los vehículos en horarios valle, entre las 00.00 y las 07.00 hrs.

Con el avance tecnológico, la mayoría de las empresas distribuidoras de energía a nivel mundial han incorporado medidores inteligentes [1]. Estos medidores son

²<https://movilidad.ute.com.uy/clientesParticulares.html>

1.2. Descripción del problema



Figura 1.3: Medidor inteligente Kaifa modelo *MA110P* colocado por UTE en los hogares de Uruguay.

capaces de recolectar potencia en intervalos de pocos minutos, comparado con los medidores tradicionales que recolectaban una única medida mensual. En Uruguay, UTE se encuentra instalando medidores inteligentes como el que se observa en la Figura 1.3, que recolectan potencia activa y reactiva cada 15 minutos y envían los datos instantáneamente. Actualmente, el 60 % de los hogares en Uruguay cuentan con medidores inteligentes y se aspira alcanzar el 100 %³ de hogares para finales de 2024. Una ventaja significativa para los usuarios es la posibilidad de acceder y analizar los datos en tiempo real, permitiéndoles ejercer mayor control sobre el consumo.

La aparición de estos medidores inteligentes conlleva la adquisición de una gran cantidad de datos, lo que plantea a las distribuidoras un escenario más adecuado para aplicar técnicas avanzadas de aprendizaje automático, permitiendo así una mejor comprensión del consumo.

1.2. Descripción del problema

1.2.1. Monitoreo de cargas

El monitoreo de cargas implica medir y analizar el consumo de energía eléctrica de uno o varios aparatos en un sistema eléctrico. Existen dos enfoques principales: la Monitorización Intrusiva de Cargas (ILM) y la Monitorización no Intrusiva de Cargas (NILM). Ambas variantes presentan desafíos y enfoques distintos, pero al mismo tiempo complementarios.

³<https://portal.ute.com.uy/noticias/en-2024-el-100-de-los-hogares-dispondran-de-medidores-inteligentes>

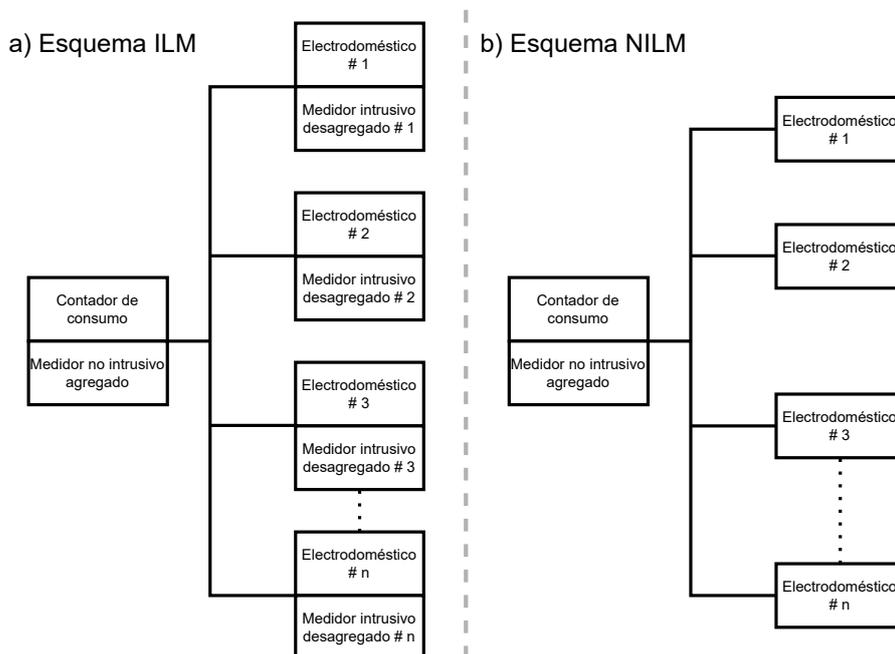


Figura 1.4: Esquema ILM y esquema NILM.

1.2.1.1. ILM

El enfoque ILM implica medir el consumo de energía eléctrica con un medidor ubicado en cada electrodoméstico del hogar. Esto significa que se requiere de la instalación de múltiples medidores para monitorear cada dispositivo eléctrico en el hogar, siendo costoso y complejo de instalar y mantener. La Figura 1.4.a ilustra el esquema de un sistema ILM.

Una de las aplicaciones más usuales de ILM es la identificación de electrodomésticos. Esta juega un papel importante en los objetivos de las empresas distribuidoras de energía en su afán de ofrecer tarifas diferenciales por tipo de electrodomésticos. Una estrategia empleada por las empresas distribuidoras consiste en proporcionar al cliente un medidor para ser instalado en un determinado electrodoméstico, permitiendo así facturar el consumo de dicho aparato de manera diferenciada. Sin embargo, esta estrategia plantea un desafío: garantizar que se haya conectado el electrodoméstico específico solicitado por la distribuidora. Esto se debe a que el usuario podría conectar otro tipo de aparato y beneficiarse indebidamente de las tarifas diferenciales ofrecidas.

1.2.1.2. NILM

El enfoque NILM utiliza únicamente un medidor para registrar la señal agregada de todo el hogar, y así estimar el consumo de energía eléctrica de los dispositivos eléctricos individuales, mediante el uso de algoritmos de desagregación. NILM fue propuesto originalmente por George W. Hart en la década de 1980 [2, 3]. La Figura 1.4.b muestra un posible esquema de NILM.

1.2. Descripción del problema

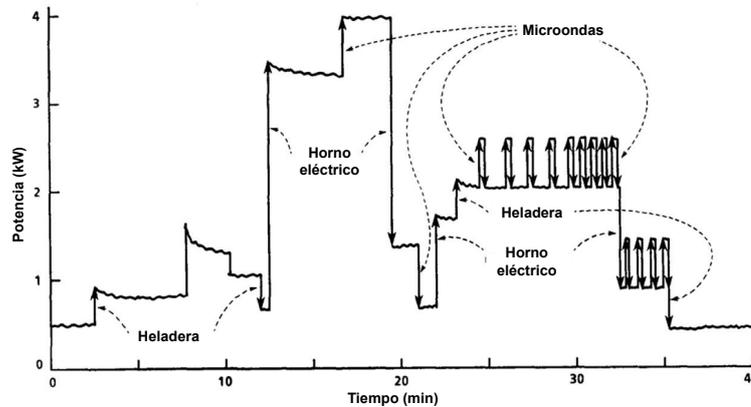


Figura 1.5: Esquema de desagregación de consumo.

El problema de NILM consiste en distinguir y atribuir a cada dispositivo el consumo de energía eléctrica dentro de una señal agregada compuesta por múltiples electrodomésticos que funcionan simultáneamente, es decir, desagregar el consumo total en sus componentes individuales. La Figura 1.5 ilustra cómo se presenta una señal agregada compuesta por el consumo de diversos electrodomésticos.

La desagregación del consumo ofrece la capacidad de identificar y diferenciar el consumo de diversos electrodomésticos en el hogar. Esto permite proporcionar información valiosa a los usuarios, quienes pueden optimizar su consumo de energía y adaptarse a incentivos específicos para ciertos electrodomésticos, sin la necesidad de implementar sistemas de submedición adicionales.

1.2.2. Intervalo de muestreo

En el contexto de monitoreo de cargas, la frecuencia de muestreo es un aspecto clave. Una frecuencia elevada implica intervalos de tiempo entre muestras menores y, por lo tanto, resultados más precisos al utilizar algoritmos para ILM o NILM. En contrapartida, la implementación de frecuencias elevadas presenta un desafío logístico debido a la necesidad de hardware potente y sistemas con mayor capacidad de almacenamiento, lo cual deviene en mayores costos.

La distinción más común es llamar *baja frecuencia* a los datos que se encuentran por debajo de la frecuencia de la red eléctrica y *alta frecuencia* a los que se encuentran por encima de ella. Un análisis exhaustivo es propuesto en [4], que divide los rangos de frecuencia en seis categorías diferentes:

- *muy-baja-frecuencia*: menores a $\frac{1}{60} Hz$ (una muestra por minuto).
- *baja-frecuencia*: entre $\frac{1}{60} Hz$ y $1 Hz$.
- *media-frecuencia*: entre $1 Hz$ y la frecuencia de la red.
- *alta-frecuencia*: entre la frecuencia de la red y $2 kHz$.

Capítulo 1. Introducción

- *muy-alta-frecuencia*: entre $2kHz$ y $40kHz$.
- *extremada-alta-frecuencia*: mayor a $40kHz$.

La elección de la tasa de muestreo determina las técnicas utilizadas para resolver el problema. A muy baja frecuencia solo se pueden detectar patrones macro, mientras que a muy alta frecuencia se pueden apreciar las no linealidades más sutiles de los electrodomésticos en las curvas de voltaje y corriente.

Cuando se analiza la literatura en una revisión actualizada [5] se observa que si bien hay muchos trabajos recientes la mayoría se centran en *media-frecuencia*, *alta-frecuencia* y *muy-alta-frecuencia*, pero hay muy pocos artículos que reporten resultados *baja-frecuencia* y *muy-baja-frecuencia*.

Ocurre que los medidores inteligentes utilizados por las compañías de distribución de energía suelen tomar medidas a una frecuencia no superior a una muestra por minuto, es decir, a *muy-baja-frecuencia*. Esto genera la necesidad de una nueva tendencia en el campo del monitoreo de cargas, que consiste en proponer sistemas que funcionen a tasas de muestreo muy bajas, requiriendo el desarrollo de nuevos algoritmos y técnicas de procesamiento de datos para poder aprovechar al máximo la información recolectada.

Tal como se mencionó previamente, UTE ha implementado una red de medidores inteligentes e intrusivos que operan a *muy-baja-frecuencia*. Este sistema ha estado operando desde hace varios años y se prevé que continúe. Además, según lo planificado, se tiene previsto alcanzar la totalidad de los hogares para finales de 2024, con lo cual la disponibilidad de datos a baja frecuencia irá en aumento. En consecuencia, esta tesis busca contribuir a la maximización del aprovechamiento de los datos disponibles.

1.2.3. Electrodomésticos de interés

La Encuesta Continua de Hogares de 2022 revela que el 88,2% de los hogares cuentan con al menos un termotanque, como se muestra en la Figura 1.6. Además, los resultados de una encuesta sobre fuentes y usos de energía realizada por la Dirección Nacional de Energía establecieron que, en promedio, el 37% de la energía eléctrica consumida a nivel residencial se destina al calentamiento de agua en termotanques. Aunque existen otros electrodomésticos que son considerados esenciales y están presentes en la mayoría de los hogares, el termotanque resulta de particular interés en el contexto uruguayo debido a su elevado consumo y amplia adopción.

Asimismo, los vehículos eléctricos son otro de los electrodomésticos de relevancia, configurando una tendencia emergente en el sector de la movilidad y con consumo energético considerable. Tomando como insumo datos suministrados por UTE, se calcula que en aquellos hogares que cuentan con vehículo eléctrico, en promedio el 75,2% de la energía consumida corresponde a este.

Los altos consumos de energía de los termotanques y vehículos eléctricos sugieren que controlar su uso puede ser una estrategia efectiva para la gestión de la demanda [6]. Por ejemplo, mediante la implementación de incentivos económicos

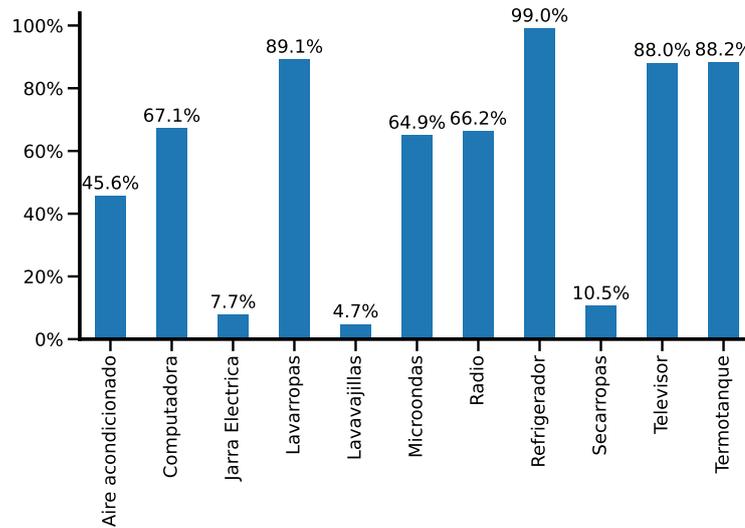


Figura 1.6: Respuestas de la Encuesta Continua de Hogares 2022 sobre si se poseen determinados electrodomésticos.

que fomenten un uso específico de estos dispositivos es posible aplanar la curva de consumo agregado.

1.3. Contexto

La tesis se enmarca en un proyecto de investigación y desarrollo en colaboración entre el Departamento de Procesamiento de Señales del Instituto de Ingeniería Eléctrica de la Facultad de Ingeniería de la UdelaR y UTE. Dicha colaboración consiste en desarrollar técnicas avanzadas de aprendizaje automático a ser aplicadas sobre datos reales del sistema eléctrico uruguayo.

1.4. Objetivos

El objetivo de esta tesis es la monitorización del consumo a *muy-baja-frecuencia*. En particular, se implementarán algoritmos genéricos de identificación de electrodomésticos con una tasa de una muestra por minuto, enfocándose en la identificación de termotanques, tal como se ilustra en la Figura 1.7.

Adicionalmente, se abordará la tarea de desagregación no intrusiva con una tasa de muestreo de 15 minutos, utilizando algoritmos genéricos enfocados en la desagregación de termotanques y vehículos eléctricos, como se muestra en la Figura 1.8.

Capítulo 1. Introducción

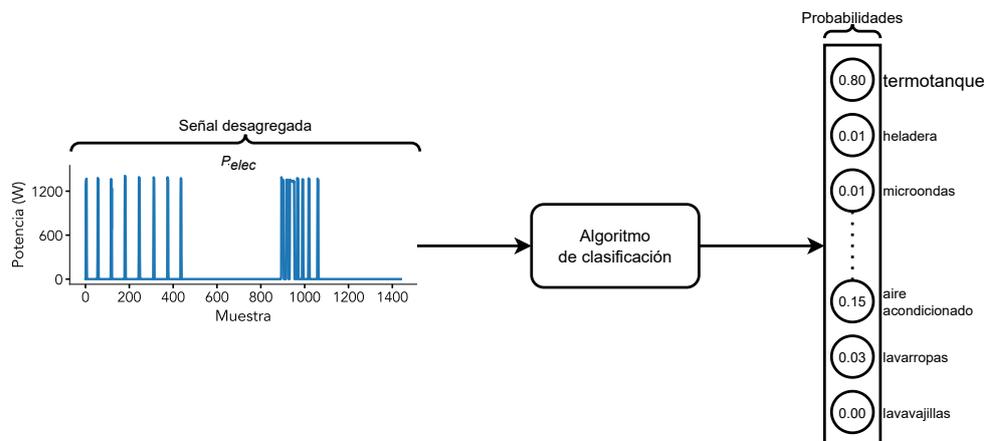


Figura 1.7: Esquema de identificación de electrodomésticos.

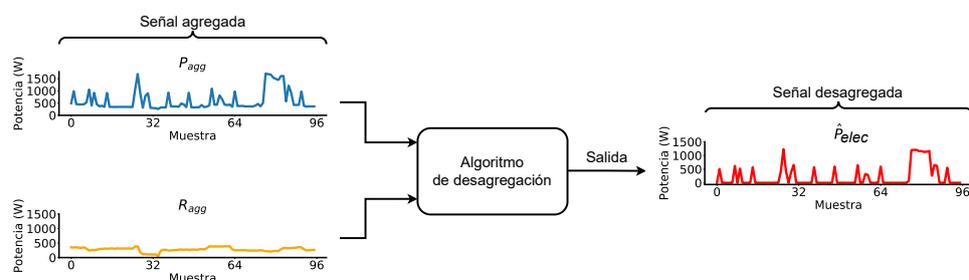


Figura 1.8: Esquema de desagregación de electrodomésticos.

1.5. Contribuciones

En este trabajo se desarrollan técnicas NILM e ILM sobre un gran volumen de datos reales adquiridos por medidores inteligentes y medidores intrusivos de Uruguay. Los métodos propuestos son potencialmente novedosos ya que se enfocan en *muy-baja-frecuencia*, un tema poco abordado en la literatura del área. En el artículo [7] presentado en la conferencia *Proceedings of the Innovative Smart Grid Technologies 2023, North America (ISGT NA), Washington, DC, USA* se incluyeron resultados de los modelos de desagregación de vehículos eléctricos evaluados en esta tesis.

Los algoritmos y códigos desarrollados fueron transferidos a UTE, permitiendo la identificación de electrodomésticos, así como la desagregación de consumo de vehículos eléctricos y termotanques. Estos modelos son utilizados por UTE en problemas concretos relacionados con la gestión de la demanda de energía. En este sentido, se han realizado talleres de transferencia con técnicos de UTE en los que se explora en detalle el código y los modelos de forma interactiva.

Asimismo, se realizó una contribución a la generación y preparación de bases de datos en un formato estándar denominado NILMTK-HDF, corrigiendo código existente en repositorios públicos y desarrollando código completamente nuevo pa-

ra otras bases de datos. En total, se corrigió o generó código nuevo correspondiente a 9 bases de datos diferentes. Esto posibilita la estandarización y accesibilidad de las bases de datos en el área del monitoreo de consumo. En el artículo [8] publicado en *2021 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America)* se presentó la base de datos NILM-UY, con el código que convierte los datos al formato NILMTK-HDF.

1.6. Estructura del documento

El cuerpo central de esta tesis se estructura de la siguiente forma:

- En el Capítulo 2 se presenta el estado del arte en ILM y NILM.
- En el Capítulo 3 se exponen los datos utilizados a lo largo del documento. Se describen en detalle los datos recolectados por UTE a través de medidores intrusivos y medidores inteligentes. También se realiza una revisión detallada de las bases de datos públicas. Además, se presenta el formato estandarizado de recolección de bases de datos NILMTK-HDF y se describen los patrones de consumo de electrodomésticos de interés, tales como termotanque y vehículo eléctrico.
- En el Capítulo 4 se implementa una técnica ILM para identificar a qué tipo de electrodoméstico corresponde una serie temporal. Se desarrollan clasificadores multiclase utilizando redes neuronales, con especial énfasis en los resultados relacionados con la identificación de termotanques. Además, se evalúa el rendimiento de los algoritmos con diferentes tasas de muestreo.
- En el Capítulo 5 se implementan técnicas NILM para la desagregación del consumo, utilizando redes neuronales. Se prueban los algoritmos sobre datos locales recopilados por el medidor inteligente cada 15 minutos, centrándose en la desagregación de termotanques y vehículos eléctricos, en iguales intervalos de tiempo. Como etiquetas para los algoritmos, se emplean los datos recolectados por medidores intrusivos cada 1 minuto. Además, se propone desagregar a una tasa de 1 minuto a partir de una entrada con tasa de muestreo de 15 minutos.
- En el Capítulo 6, se detalla la implementación en producción llevada a cabo por el equipo técnico de Consumo Inteligente de UTE. Asimismo, se exponen diversas aplicaciones que demuestran el potencial de los modelos en la resolución de distintos problemas de interés en el sector.
- Por último, el Capítulo 7 reúne las conclusiones del presente trabajo.

Capítulo 2

Estado del arte

En este capítulo se lleva a cabo una revisión exhaustiva del estado del arte en técnicas de monitoreo de consumo, tanto en NILM como en ILM. En ambos casos se realiza una revisión general, para luego enfocarse en los trabajos realizados a bajas frecuencias y en los electrodomésticos de interés. Es oportuno señalar que la literatura disponible sobre ILM es más acotada que para el caso de NILM.

2.1. NILM: Desagregación de consumo

Desde un punto de vista académico, se puede considerar que NILM es un área madura y el desafío actual consiste en desarrollar algoritmos eficientes y con buen desempeño en operación. Por ejemplo, en [9], un trabajo reciente que presenta una revisión sobre NILM, se destaca cómo se ha avanzado en la obtención de buenos desempeños. Sin embargo, al analizar en mayor profundidad los trabajos, se observa que si bien hay muchas investigaciones recientes, la mayoría se centran en la desagregación a altas y bajas frecuencias. No obstante hay muy pocos artículos que reporten resultados en muy bajas frecuencias.

En el contexto de NILM, la frecuencia de muestreo es un aspecto clave. Una frecuencia elevada proporciona más información y por lo tanto resultados más precisos en la desagregación. Estudios como [10, 11] demuestran que para lograr el máximo potencial en los algoritmos NILM, es esencial utilizar frecuencias superiores a 4 kHz. Además, en [12] se sugiere que incluir armónicos de frecuencias altas mejora la desagregación, principalmente de aparatos eléctricos de bajo consumo. Sin perjuicio de lo anterior, el uso de frecuencias elevadas presenta un desafío práctico debido a la necesidad de hardware y software potente y medidores más costosos.

A *alta-frecuencia*, *muy-alta-frecuencia* y *extremada-alta-frecuencia*, los beneficios son notorios ya que se preserva toda la señal y se pueden extraer características de calidad. Entre ellas, se destaca la curva de trayectoria V-I [11, 13, 14, 15, 16], los armónicos de corriente [11, 15, 17, 18, 19, 20], el factor de forma de la corriente [11] y los coeficientes de la transformada de Wavelet [21, 22].

Por otro lado, en el caso de las *media-frecuencia*, *baja-frecuencia* y *muy-baja-*

Capítulo 2. Estado del arte

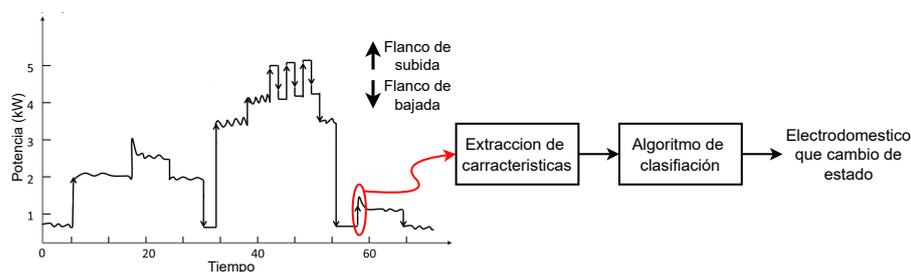


Figura 2.1: Esquema de desagregación NILM usando la estrategia *event-based*.

frecuencia, los medidores suelen proporcionar únicamente características como la potencia activa, potencia reactiva, potencia aparente, corriente o voltaje, promediadas a la frecuencia de trabajo. En consecuencia, no es posible realizar la extracción de características sofisticadas como cuando se tiene el voltaje y corriente a frecuencias altas.

La literatura sobre NILM se ha enfocado especialmente en un rango de frecuencias limitado. Esta situación se debe a la escasa variedad en la frecuencia de muestreo de las bases de datos disponibles. En [5], se resalta que las bases de datos REDD [23], UK-DALE [24] y SMART [25] son las más empleadas y, en conjunto, se utilizan en más de la mitad de los estudios. Estas bases de datos, así como otras también populares, fueron adquiridas a frecuencias entre $1Hz$ y $\frac{1}{60}Hz$. Como resultado, la literatura se ha centrado principalmente en estos rangos de frecuencias.

A continuación se realiza una revisión de los trabajos a baja frecuencia, para luego hacer foco específico en los trabajos a *muy-baja-frecuencia* sobre los electrodomésticos de interés (los autos eléctricos y los termotanques).

2.1.1. Enfoques a baja frecuencia

El enfoque clásico para abordar NILM en baja frecuencia se conoce como *event-based*. Los trabajos fundacionales de Hart [2, 3] en esta temática siguen este enfoque, el cual consiste en detectar eventos en la potencia agregada (flancos de subida y bajada) que representan cambios de estado en un electrodoméstico. Luego, se extraen características de estos eventos (por ejemplo, cambio en potencia, duración y/o área) y se aplica un algoritmo de clasificación para asignar el cambio a un electrodoméstico específico. La Figura 2.1 ilustra esquemáticamente el proceso de desagregación basado en eventos. Para la etapa de clasificación de eventos se han utilizado algoritmos clásicos de aprendizaje automático como SVM [26], Naive Bayes [18, 27] y árboles de decisión [21, 28], así como técnicas más avanzadas, como Dynamic Time Wrapping [29, 30]. Más recientemente, se han utilizado técnicas de Graph Signal Processing (GSP) [31, 32, 33] en las que el modelado del grafo se relaciona con los flancos de subida y bajada.

Por otro lado, existen los métodos *no-event-based*, los cuales no se centran en detectar eventos de cambio de estado en la señal de consumo agregada. En su lugar, utilizan técnicas de aprendizaje automático y procesamiento de señales

2.1. NILM: Desagregación de consumo

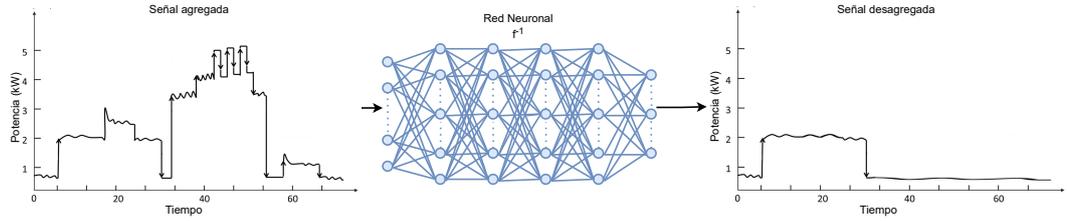


Figura 2.2: Esquema de desagregación NILM usando *Deep Learning*.

para modelar y estimar el consumo de los electrodomésticos a partir de la señal agregada. Los Modelos Ocultos de Markov (Hidden Markov Models, HMM) [34, 35, 36, 37] fueron uno de los enfoques más populares en un inicio. Los mismos consisten en una representación probabilística de las series temporales mediante estados, en la que cada nivel de consumo para cada electrodoméstico se define como un estado y cada uno de estos tiene una probabilidad de transición.

Otro enfoque popular dentro de los métodos *no-event-based* es Source Separation. Este modela el problema como uno de optimización con restricciones. Algunos algoritmos ampliamente utilizados en este enfoque son Non-Negative Matrix Factorization (NMF) [38, 39], Independent Component Analysis (ICA) [40] y Sparse Component Analysis (SCA) [41]. De forma simplificada, NMF consiste en modelar el problema como uno de mínimos cuadrados lineales con restricciones, como se muestra en la siguiente ecuación:

$$\min_{a \geq 0} \|\mathbf{x} - \mathbf{D}\mathbf{a}\|_2^2.$$

Donde \mathbf{x} es un vector que contiene la señal agregada y \mathbf{D} es llamada matriz de firmas que contiene en cada columna una firma \mathbf{d}_i de un electrodoméstico:

$$\mathbf{D} = \begin{pmatrix} | & | & \dots & | \\ \mathbf{d}_1 & \mathbf{d}_2 & \dots & \mathbf{d}_T \\ | & | & \dots & | \end{pmatrix}.$$

Mientras que \mathbf{a} , que es la variable de optimización, representa cuanto debería aportar cada \mathbf{d}_i para reconstruir la señal agregada. En este enfoque, la idea principal es descomponer la señal agregada de consumo en una combinación lineal de las señales de consumo individuales de los electrodomésticos.

Las alternativas mencionadas anteriormente han sido reemplazadas en gran medida por técnicas de redes neuronales profundas o Deep Learning (DL), ya que han representado una gran mejora en los trabajos de NILM desde su aparición en [42]. Las técnicas de DL se encuentran dentro de los enfoques *no-event-based*; la entrada a la red neuronal suele ser la señal agregada de potencia, mientras que la salida es la señal desagregada del electrodoméstico de interés. Lo usual es tener una red neuronal por cada electrodoméstico que se quiere desagregar. La Figura 2.2 ilustra esquemáticamente el proceso descrito.

El trabajo [42] fue el precursor en el uso de redes neuronales para NILM, implementando arquitecturas de redes neuronales recurrentes (LSTM) y Convolutiva

Capítulo 2. Estado del arte

Denoising Autoencoders (DAE). Desde entonces, se han explorado diversos enfoques para mejorar el desempeño en NILM. Se han modificado las arquitecturas de las redes neuronales; por ejemplo, en [43] se propone utilizar la arquitectura GRU, una variante de las LSTM; en [44] se evalúa RCNN, una red neuronal convolucional recurrente; y en [45] se presenta VRNN, una red neuronal recurrente variacional. Además, se han investigado mejoras en las arquitecturas de redes neuronales convolucionales, como en [46], que introduce convoluciones dilatadas inspiradas en Wavenet. En los últimos años, con el auge de los mecanismos de atención, han surgido trabajos que utilizan la arquitectura Transformer [47], por ejemplo, en [48] se propone una arquitectura basada en Bert [49], y variantes de esta última arquitectura han sido presentadas en [50, 51, 52].

Por otro lado, se han explorado mejoras en las entradas y salidas de las redes neuronales. Esto incluye la incorporación de múltiples características en la entrada, como se muestra en [53], o en [54], donde se implementó una LSTM que recibe cinco componentes de entrada: potencia activa, reactiva, aparente, corriente y desfase, lo que resultó en un mejor desempeño en comparación con una sola componente.

Existen también trabajos que modificaron las configuraciones de entrada y salida de las redes neuronales. En particular, se han propuesto tres variantes: secuencia a secuencia (*seq2seq*), secuencia a subsecuencia [55] (*seq2subseq*) y secuencia a punto [56, 57] (*seq2point*). La entrada en cualquier caso es una secuencia de longitud L , pero la salida depende de la variante. En *seq2point*, la salida es un punto único; en *seq2subseq*, es una secuencia más corta que la entrada; y en *seq2seq*, es una secuencia de igual longitud L . La Figura 2.3 ilustra estas tres variantes.

Los enfoques *seq2point* y *seq2subseq* han mostrado un mejor desempeño que *seq2seq*. La razón detrás de estos resultados es que puntos en los extremos con *seq2seq* tienen un campo receptivo más pequeño, mientras que los puntos cercanos al medio tienen un campo receptivo más amplio. Sin embargo, estas variantes tienen una desventaja evidente: para cada señal de longitud L , se deben realizar L inferencias en *seq2point* y $\frac{L}{N}$ inferencias en *seq2subseq*, lo que las hace considerablemente más costosas que *seq2seq*.

2.1.2. Enfoques sobre termotanques y vehículos eléctricos a muy baja frecuencia

En la literatura, los estudios enfocados en muy baja frecuencia son poco comunes. A pesar de ello, existen algunos enfoques específicos para abordar problemas en este rango. Por ejemplo, en [58] se proponen algoritmos genéticos con una muestra por hora, mientras que en [59] se presenta un algoritmo basado en técnicas de clustering y optimización sobre la potencia activa y reactiva.

Una estrategia común para abordar problemas en estas frecuencias es incorporar información externa. En [60] se desagrega el consumo a un periodo de una muestra por hora incorporando información externa sobre la temperatura ambiente. En [61] se incorpora información sobre la composición de la vivienda, como el tamaño, la cantidad de ocupantes y el número de habitaciones.

Sin embargo, la metodología más común es utilizar los mismos enfoques que

2.1. NILM: Desagregación de consumo

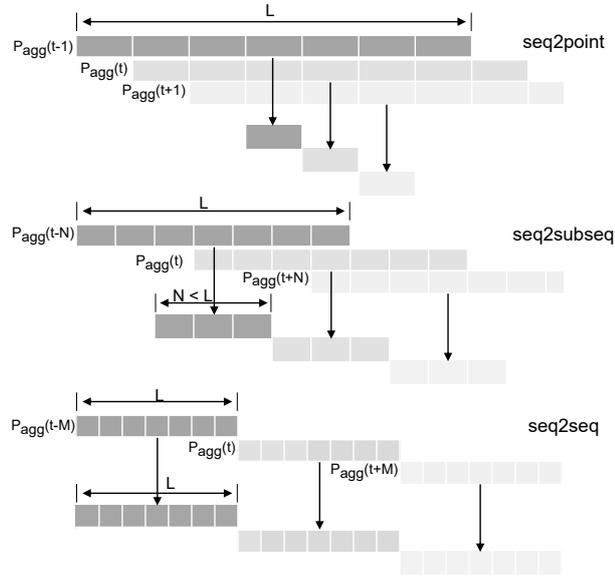


Figura 2.3: Arriba: *seq2point*. Medio: *seq2subseq*. Abajo: *seq2seq*.

se han descrito para frecuencias bajas. En [62] se utiliza un enfoque *no-event-based* con técnicas NMF a una tasa de muestreo de 30 minutos. En [63] se utiliza un enfoque *event-based* con SVM, árboles de decisión y KNN. Mientras que en [64, 65, 66] se proponen técnicas de GSP.

En trabajos más recientes, como [67], se utilizan técnicas de redes neuronales y se las compara con otros enfoques, incluyendo GSP y HMM. Los resultados de este trabajo sugieren que solo es posible desagregar correctamente el consumo a *muy-baja-frecuencia* para los electrodomésticos de gran consumo de potencia.

Los estudios mencionados anteriormente, aunque se enfocan en baja frecuencia, no abordaron la desagregación de termotanques ni de vehículos eléctricos. Esto se debe a que, si bien los termotanques son ampliamente utilizados en Uruguay, no son comunes en otras regiones. Por otro lado, los vehículos eléctricos son relativamente nuevos, lo que resulta en pocas investigaciones sobre ellos en el contexto de NILM.

Según [67], que realiza una revisión exhaustiva hasta junio de 2020, no existían trabajos a muy baja frecuencia en relación a estos electrodomésticos. Posterior a esta fecha, se encontró un único trabajo sobre termotanques a *muy-baja-frecuencia* que fue [68]. Este estudio propone técnicas basadas en reglas para desagregar el consumo de termotanques en Costa Rica con una tasa de muestreo de 15 minutos. Los resultados de este trabajo serán utilizados como punto de referencia en este trabajo de tesis.

En cuanto a los vehículos eléctricos, en [69], se utilizaron técnicas de árboles de decisión y redes neuronales para desagregar el consumo de un vehículo eléctrico desde 1 minuto hasta 15 minutos. Por otro lado, en [7] se introduce un enfoque basado en reglas análogas a las presentadas para termotanques en [68], pero adaptado a vehículos eléctricos, que además realiza una comparación con diversas arquitecturas de redes neuronales. En [70] se propone un método utilizando PCA y SVM

aplicado a la base de datos Dataport, aunque no es a muy bajas frecuencias, sino que a tasas de 1 minuto. Teniendo en cuenta esta revisión, el trabajo más similar a lo que se plantea en esta tesis es [69], que será utilizado como punto de referencia para comparar los resultados obtenidos.

2.2. ILM: Identificación de electrodomésticos

Los trabajos en el área de ILM y específicamente en la identificación de electrodomésticos, son menos abundantes en comparación con la literatura existente en NILM. El enfoque más común para la identificación consiste en utilizar aprendizaje supervisado a altas frecuencias.

En trabajos como [71, 72] se utilizan frecuencias muy altas y muestran resultados considerablemente superiores en comparación con los trabajos a bajas frecuencias. Al igual que en NILM, para emplear altas frecuencias, es común realizar extracción de características diseñadas a mano, seguido de clasificadores como SVM o Random Forest. En [73] se utiliza un enfoque mediante el análisis espectral usando transformadas de Wavelet. La trayectoria V-I se utilizó para clasificar electrodomésticos en [74, 75]. Características como la Total Harmonic Distortion (THD) y el factor de cresta, comunes en procesamiento de señales, se utilizaron en [72, 76, 77]. En [78] se utiliza únicamente la potencia activa y reactiva.

También, se han utilizado armónicos de alta frecuencia mediante DFT y FFT en [72, 79, 80, 81]. Analizando las componentes espectrales, en [82] se presenta la relación entre la magnitud del armónico fundamental con la media espectral, así como el Inrush Current Ratio, que relaciona el valor cuadrático medio de la corriente al final y al inicio.

Por otro lado, el estudio [83] ha sido reconocido como un trabajo fundamental en el campo de identificación de electrodomésticos. En el mismo se evaluaron y compararon diversos descriptores, como los histogramas de corriente y voltaje, la trayectoria V-I, la potencia activa y reactiva, los armónicos, entre otras características. La conclusión de esta investigación indicó que al utilizar altas frecuencias, la trayectoria V-I y el histograma de corriente y voltaje resultaron ser las características más relevantes. Además, se determinó que el clasificador más efectivo fue Random Forest.

Trabajos recientes se enfocan en proponer métodos capaces de funcionar en tiempo real y dentro del dispositivo de medida, técnica conocida como edge computing. En este sentido, en [84, 85, 86] se presentan enfoques implementados dentro del medidor capaces de clasificar electrodomésticos utilizando solo 10 segundos de datos recolectados a alta frecuencia, empleando clasificadores SVM.

Hasta ahora, se han discutido técnicas de ILM aplicables a altas frecuencias. No obstante, estas técnicas no resultan adecuadas para datos a bajas frecuencias debido a que las características se calculan a partir de datos de alta frecuencia. Tras llevar a cabo una revisión exhaustiva de la literatura, se ha observado que existen relativamente pocos estudios enfocados en la identificación de electrodomésticos a bajas frecuencias. En [87] se propone el uso de redes neuronales y SVM como clasificadores para identificar electrodomésticos utilizando la base de datos UK-

2.2. ILM: Identificación de electrodomésticos

DALE [88] que tiene datos de medición cada 6 segundos. En [86] se utiliza la base de datos Tracebase, que tiene datos de medición cada 1 segundo y cada 8 segundos, y se aplican redes neuronales, árboles de decisión y k-NN como clasificadores.

Un artículo relevante para profundizar en ILM y sus aplicaciones es [89], en el cual se presenta una revisión sistemática de los distintos enfoques y trabajos en ILM. Este artículo también identifica los electrodomésticos más comunes en los estudios de ILM, que son heladeras, microondas, televisores y lavarropas. No obstante, se debe destacar que no se encontraron trabajos previos que aborden la identificación de termotanques mediante ILM.

Capítulo 3

Generación y preparación de bases de datos

3.1. Introducción

Las bases de datos son fundamentales para el desarrollo e investigación de nuevas técnicas en el área del monitoreo de consumo eléctrico. La adquisición de las bases de datos, tanto ILM como NILM, requiere la instalación de un medidor para el consumo total del hogar y varios medidores en distintos electrodomésticos, siguiendo un esquema de ILM como el de la Figura 1.4 del Capítulo 1. Es importante resaltar que emplear bases de datos recolectadas mediante un esquema ILM en algoritmos de NILM no constituye un error, puesto que muchos de los algoritmos son supervisados y requieren igualmente datos intrusivos desagregados de los electrodomésticos para funcionar de manera adecuada.

En los últimos años, se ha experimentado un incremento significativo en la cantidad de bases de datos disponibles para este tipo de problema. Esto es ventajoso porque permite a los investigadores y desarrolladores probar y mejorar sus algoritmos sobre datos más diversos y representativos. Además, la disponibilidad de nuevas bases de datos ayuda a aumentar la precisión y la eficacia de los modelos de aprendizaje automático.

A modo de ejemplo, en la Figura 3.1 se muestran las series temporales presentes en la base UK-DALE [88] recolectada en Reino Unido.

Las bases de datos pueden variar en características en función de los siguientes aspectos:

- Frecuencia de muestreo: Existen bases de datos con muestras adquiridas a 30 kHz [83] hasta bases que toman muestras cada 10 minutos [90] o incluso horas.
- Magnitudes adquiridas: Voltaje, corriente, potencia activa, potencia reactiva, potencia aparente, THD, entre otras.
- País de adquisición: La región o país de origen puede influir en los patrones de consumo de energía en el hogar, ya que no en todos los países se suele utilizar

Capítulo 3. Generación y preparación de bases de datos

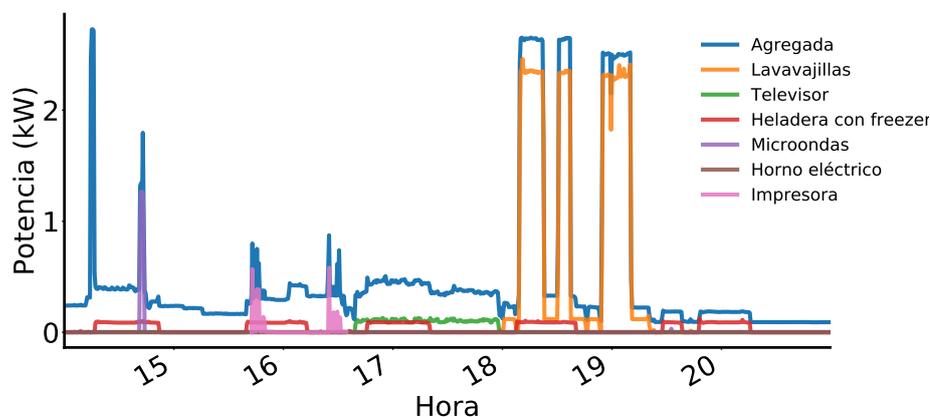


Figura 3.1: Series temporales de consumo del Hogar 1 de la base de datos UK-Dale para un día en particular.

los mismos electrodomésticos. Por ejemplo, en EE.UU. es muy extendido el uso de aire acondicionado mientras que en Francia es casi nulo. Además, el costo de la energía en relación a los ingresos puede afectar los patrones de consumo en diferentes países.

- **Electrodomésticos seleccionados:** No todos los hogares tienen los mismos electrodomésticos y la selección de cuáles medir esta sujeta al criterio e interés específico de la persona que recolecta la base de datos.
- **Variedad de electrodomésticos:** Dos electrodomésticos del mismo tipo pueden ser adquiridos a la misma frecuencia y registrar las mismas magnitudes, pero pueden presentar formas de consumo totalmente distintas.

La calidad de una base de datos se mide en función de la cantidad y variedad de electrodomésticos submedidos incluidos en ella. Por lo tanto, a mayor cantidad y variedad de electrodomésticos submedidos presentes en una base de datos, mayor será su utilidad para los investigadores, ya que proporcionará una representación más detallada de los patrones de consumo de energía en el hogar.

Dada la gran variabilidad en las características de las bases de datos, se ha desarrollado una iniciativa dentro del proyecto público NILMTK para implementar un formato de almacenamiento de datos unificado denominado NILMTK-HDF. Muchas de las bases de datos de NILM más populares se encuentran disponibles en este formato, y la ventaja de utilizarlo radica en la posibilidad de implementar algoritmos lo suficientemente genéricos e independientes de la base de datos que se esté utilizando. De esta manera, se simplifica la investigación y el desarrollo de nuevas técnicas de aprendizaje automático en el área.

Este capítulo se estructura en cinco secciones. En la primera, se presenta una descripción detallada de las bases de datos públicas empleadas en el presente trabajo. La segunda sección se enfoca en las bases de datos propias recolectadas por

el grupo de FING y la empresa UTE, incluyendo detalles de su recolección, características y relevancia en el contexto de este estudio. En la tercera sección, se realiza una comparación de las características de las bases públicas y propias presentadas.

En la cuarta sección, se introduce el formato NILMTK-HDF y se explica como contribuye a disminuir la barrera que implica tener bases de datos en múltiples formatos distintos. En la quinta sección se muestra uno de los aportes fundamentales de este trabajo, que es la publicación del código para la conversión de varias bases de datos a formato NILMTK-HDF.

En la sexta sección, se exploran los patrones de consumo de diferentes electrodomésticos, centrándose en los termotanques y vehículos eléctricos. Se presentan análisis detallados de los patrones de consumo, permitiendo una mejor comprensión de su uso.

3.2. Bases de datos públicas

La disponibilidad de bases de datos públicas es fundamental para el desarrollo y evaluación de algoritmos de aprendizaje automático en el campo de la monitorización de consumo. Estas son importantes para promover la investigación abierta y colaborativa, ya que a medida que se recopilan y comparten más bases de datos, es posible desarrollar y evaluar nuevos métodos.

En esta sección, se describen brevemente las bases de datos públicas utilizadas en este documento, incluyendo detalles sobre su origen, contenido y frecuencia de muestreo.

- **AMPDs2** [91]: The Almanac of Minutely Power dataset (AMPds2) es un conjunto de datos abierto que incluye 2 años de datos de consumo de un hogar en Canadá entre 2013 y 2014. Los datos agregados y de electrodomésticos son muestreados cada 1 minuto. Contiene un total de 21 medidores intrusivos, los cuales adquieren las señales de tensión, corriente, potencia activa, potencia reactiva y potencia aparente, así como otras medidas no específicamente de electricidad como el estado del tiempo, gas natural, uso de agua, etc. También se dispone de información de facturación para el análisis de costos.
- **COMBED** [92]: Commercial building energy dataset (COMBED) fue publicado en 2014, es el primer conjunto de datos no residencial. Los datos de consumo de energía se recopilaron en el IIT de Delhi, India, un campus educativo constituido por 8 edificios institucionales. Los medidores se emplearon en todo el campus para recoger las mediciones de potencia activa y corriente. La duración total es de un mes y la frecuencia de muestreo es de 30 segundos.
- **Dataport**¹ [93]: Es un conjunto de datos recopilado desde 2009 hasta la

¹Se agradece al Dr. Di Martino, ya que en el marco de una estadía en la Universidad de Duke pude tener acceso a la versión *University Free* de Dataport.

Capítulo 3. Generación y preparación de bases de datos

actualidad en los Estados Unidos, considerado uno de los más grandes en este momento. Contiene mediciones diarias del uso y generación de energía a nivel de más de 1000 hogares, destacando la diversidad de los consumidores y la variedad en los periodos de recolección. Sin embargo, este conjunto de datos no está disponible públicamente, aunque existe una versión gratuita (*University Free*) que contiene mediciones de 75 hogares de Texas, 25 de Nueva York y 25 de California durante periodos de no más de 1 año, con una muestra por segundo de potencia activa agregada y desagregada.

- **DEDDIAG** [94]: Domestic Electricity Demand Dataset for Individual Appliances in Germany (DEDDIAG) es una base de datos recolectada en Alemania y publicada en 2021. Contiene 15 hogares alemanes durante un periodo de hasta 3,5 años. La base de datos contiene un total de 50 electrodomésticos registrados a una frecuencia de 1 Hz, incluyendo lavadoras, lavavajillas, y refrigeradores, entre otros. Uno de los hogares también incluye lecturas trifásicas de la red eléctrica, que pueden ser utilizadas para tareas de desagregación. Además, DEDDIAG contiene anotaciones manuales de eventos para 14 electrodomésticos, lo que proporciona información precisa sobre los tiempos de inicio y finalización de los mismos.
- **DRED** [95]: Dutch residential energy dataset (DRED) es una base de datos residencial publicada en 2015 que contiene mediciones de consumo eléctrico de un hogar en los Países Bajos. DRED incluye información tanto para la señal agregada como para la intrusiva, durante un período total de más de seis meses. En cuanto a las medidas intrusivas, se registran datos de doce dispositivos a una frecuencia de muestreo de 1 Hz. Además, se proporciona información relevante sobre los metadatos del hogar, como el número de residentes, la disposición de la vivienda y la correspondencia entre los dispositivos y su ubicación en el hogar. La disponibilidad de esta información adicional es útil para el análisis y la interpretación de los patrones de consumo de energía en el hogar.
- **ECO** [96]: Electricity consumption and occupancy (ECO) se compone de mediciones de electricidad recolectadas de 6 hogares durante más de 8 meses en Suiza en el año 2014. La potencia activa, la tensión y la corriente se midieron a una frecuencia de 1 Hz. Además, posee metadatos del hogar.
- **ENERTALK** [97]: Incluye datos recolectados de 22 casas en Corea del Sur, durante un periodo de 29 a 122 días para cada casa durante 2019. En general, el conjunto de datos contiene medidas de 5 electrodomésticos por casa. Este conjunto de datos proporciona mediciones de potencia activa y reactiva para la señal agregada y el consumo de energía individual para cada aparato, con una frecuencia de muestreo de 15 Hz.
- **GeLaP** [98]: German Labeled Dataset for Power Consumption (GeLaP) es conjunto de datos que fue recolectado entre septiembre de 2019 y julio de 2020 en Alemania. Se recopiló información del consumo de energía

3.2. Bases de datos públicas

eléctrica de 20 hogares utilizando medidores inteligentes con una resolución de aproximadamente 1 Hz. Además, se midió el consumo de energía de 10 electrodomésticos en cada hogar donde la carga eléctrica indica interacción humana directa.

- **GREEND**[99]: Fue recolectado en Austria e Italia en 2014, y es el primer conjunto de datos de 1 Hz en la literatura. Se recopiló información de consumo en nueve casas. La campaña de medición se llevó a cabo dentro del proyecto MONERGY, cuyo objetivo era proponer soluciones para reducir el consumo de energía en las regiones de Carintia en Austria y Friuli-Venezia en Italia.
- **iAWE** [100]: Indian dataset for Ambient Water and Energy (iAWE) se publicó en 2013. Contiene datos ambientales, de agua y de electricidad de un edificio residencial de Delhi, India. La duración total es de aproximadamente 73 días y las mediciones se recogen de 33 sensores. Los registros proporcionan información sobre la potencia activa, reactiva y aparente, la tensión y la corriente con un período de muestreo de 1 a 6 segundos, lo que representa a más de 63 electrodomésticos.
- **IDEAL** [101]: Esta base de datos incluye 255 hogares del Reino Unido durante casi 22 meses entre 2020 y 2021, así como datos de gas, temperatura y humedad. Para 39 de estos hogares, se dispone de información más detallada, incluyendo el uso de electrodomésticos individuales y datos de radiadores individuales.
- **MORED**[102]: Moroccan Buildings' Electricity Consumption Dataset (MORED) es una base de datos que contiene datos de consumo de energía eléctrica de diversos edificios de Marruecos. Se ha comenzado a recolectar en 2019 y continúa hasta la actualidad. Además de proporcionar información sobre el consumo de energía eléctrica agregado del hogar, también incluye datos sobre el consumo de varios electrodomésticos, tanto para vecindarios acomodados como desfavorecidos. Los datos se adquirieron a frecuencias de muestreo de $\frac{1}{5}$ Hz o $\frac{1}{10}$ Hz de 12 hogares. La base de datos incluye metadatos relativos a las características del hogar. Es la única base de datos de África que contiene información sobre hogares de bajos recursos.
- **RAE** [103]: La base de datos The Rainforest Automation Energy (RAE) fue publicada en 2018 e incluye datos de consumo eléctrico con una frecuencia de muestreo de 1 Hz de dos viviendas residenciales de Estados Unidos. Además de los datos de energía, se incluyen datos ambientales y de sensores. La información de los submedidores de una de las viviendas captura el uso de una bomba de calor y una suite de alquiler. La base de datos destaca por la granularidad de los datos, la información adicional y el nivel de detalle de los datos de los medidores inteligentes.
- **REDD** [23]: Reference Energy Disaggregation Data Set (REDD) fue creada en 2011 en el MIT, Estados Unidos. La base contiene la información del mo-

Capítulo 3. Generación y preparación de bases de datos

nitoreo de 10 hogares durante cuatro meses. De cada casa se tienen medidas de la potencia consumida de más de 20 electrodomésticos individuales, cada un segundo, y la medida agregada con una frecuencia de muestreo de 15kHz. La base especialmente diseñada para la tarea de identificación automática de consumos pesa más de 1TB. El hardware utilizado para la recolección de datos en el interior de las casas, es de la empresa Enmetric con comunicación DHCP en una red LAN. El sistema de medida global fue realizado utilizando un osciloscopio y un medidor de corriente conectados a un conversor A/D de 24 bits para medir voltaje y corriente, respectivamente. Los medidores se conectaban a un laptop de forma local que almacenaba en un disco duro 11GB de datos por día para cada casa.

- **REFIT** [104]: Fue publicada en 2017 e incluye datos de 20 hogares del Reino Unido, con medidas ininterrumpidas durante todo el periodo de dos años. Las lecturas tienen una tasa de muestreo de 8 segundos para las medidas intrusivas y no intrusivas de potencia activa. Además, tres hogares tienen paneles solares instalados, lo que ha llevado a la exclusión de estos de la mayoría de los estudios de investigación sobre desagregación energética.
- **SynD** [105]: Synthetic energy dataset (SynD) es una base de datos sintética creada en Austria que simula el consumo de energía eléctrica en una vivienda durante 180 días. Para su construcción, se recolectaron mediciones de 21 electrodomésticos diferentes en dos ubicaciones residenciales en Austria. Los datos incluyen mediciones agregadas y de los 21 electrodomésticos individuales con una frecuencia de muestreo de 5 Hz. Durante la campaña de mediciones, se observaron los patrones de consumo y se extrajeron los ciclos de funcionamiento para iniciar el proceso de simulación. A diferencia de las bases de datos reales, la construcción de esta base de datos sintética evita la necesidad de periodos de captura prolongados y un gran número de recursos para la adquisición de datos de múltiples dispositivos, además de evitar mediciones corruptas debido a fallas de equipo.
- **UK-DALE** [24]: UK Domestic Appliance-Level Electricity (UK-DALE) fue recolectada entre 2013 y 2017 en Reino Unido, mide el consumo de energía de 5 hogares. El consumo agregado es adquirido a 16kHz, mientras que cada electrodoméstico es medido cada 6 segundos. Tres de las casas tienen medidos hasta 20 o más electrodomésticos de forma completa. La duración de la adquisición varía de casa a casa, siendo la que tiene mayor cantidad de datos medida desde 2013 hasta 2017. Es una base de datos de gran tamaño si se quiere obtener la versión a alta frecuencia, aproximadamente 1TB.

3.3. Bases de datos propias

A pesar de la existencia de bases de datos públicas, en algunos casos puede ser necesario recolectar datos específicos para un fin en particular. En tales casos, se requiere de la recolección de datos a través de dispositivos de medición, lo que

implica la creación de una base de datos propia. Estas bases de datos pueden ser de gran utilidad para evaluar algoritmos de aprendizaje automático específicos y para obtener conocimientos sobre el consumo de energía en situaciones particulares o locales.

En esta sección, se presentan las bases de datos propias utilizadas en este trabajo de investigación, obtenidas tanto por el grupo de investigación FING como por la empresa UTE. Dado el interés en electrodomésticos como termotanques, aires acondicionados y vehículos eléctricos, se recolectaron datos centrados en estos equipos. Se detallan los procedimientos de recolección y sus características.

Una contribución importante de este trabajo fue desarrollar conversores al formato NILMTK-HDF de cada una de las bases de datos propias.

3.3.1. Base de datos de termotanques (UTEFING_TT)

Esta base de datos ha sido recolectado desde 2019 hasta la actualidad por UTE y consta de medidas agregadas de potencia activa y reactiva cada 15 minutos, así como de medidas desagregadas del consumo del termotanque cada 1 minuto.

En los últimos años, UTE ha comenzado a instalar medidores inteligentes Kaifa modelo *MA110P*, como el que se muestra en la Figura 1.3 del Capítulo 1, los cuales adquieren la potencia activa y reactiva cada 15 minutos y la envían a servidores centrales en UTE mediante fibra óptica. La mayoría de los hogares de Uruguay cuentan con estos medidores inteligentes, por lo que los datos agregados de esta base de datos provienen de ellos.

Por otro lado, los datos desagregados se recolectan mediante medidores intrusivos, como los que se muestran en la Figura 1.2 del Capítulo 1. Estos medidores intrusivos recolectan la potencia activa cada 1 minuto mediante comunicación inalámbrica GSM. Fueron colocados en hogares de clientes que se ofrecieron voluntariamente a cambio de pequeños incentivos económicos, lo que les proporcionó funciones adicionales como la capacidad de controlar el consumo de forma remota y acceder a las curvas de consumo en tiempo real. Estos clientes voluntarios proceden de varios departamentos del país, como Canelones, Montevideo, Salto, Paysandú, Maldonado, Río Negro, Colonia y San José. En total la base de datos cuenta con datos desagregados de termotanques correspondientes a 478 clientes.

En la Figura 3.2 se presenta un ejemplo de las curvas de consumo agregadas y desagregadas presentes en un hogar en particular de la base de datos. Notar que el consumo desagregado es superior al agregado y no se debe a un error, ya que tienen tasas de adquisición distintas.

Una versión anterior de esta base de datos fue publicada en [106], donde se describe la infraestructura de adquisición utilizada hasta noviembre de 2020. Aunque se han realizado actualizaciones en los medidores intrusivos conectados a los termotanques y se ha incrementado la cantidad de datos después de esa fecha, la descripción de la infraestructura y el proceso de recolección de datos sigue siendo válida.

Cabe mencionar que existen estudios académicos que emplean la versión previa de esta base de datos, pero no abordan los problemas de desagregación ni identi-

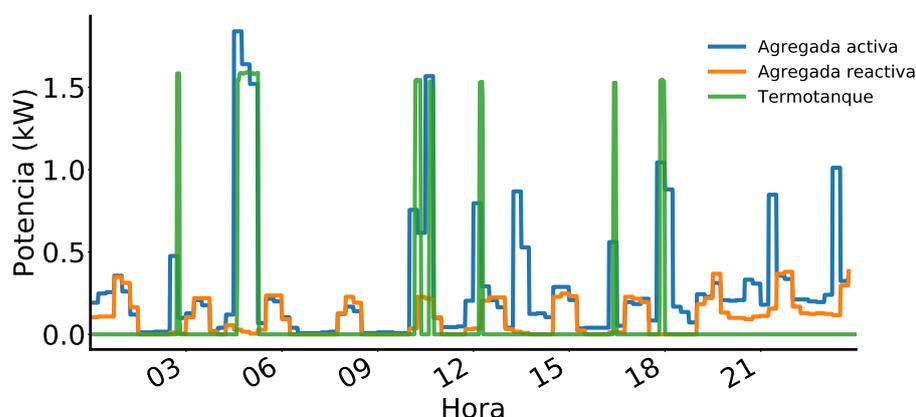


Figura 3.2: Series temporales de consumo para un hogar de la base de datos de termotanques en un día en particular.

ficación de consumos eléctricos. En [107], se presenta una propuesta para estimar la disconformidad de los clientes residenciales al controlar de forma remota sus termotanques. En [108], se utiliza Map-Reduce para generar curvas de consumo agregado representativas y clasificar las curvas en grupos similares. Por último, en [109], se estima el consumo agregado de los clientes en la hora posterior.

3.3.2. Base de datos de vehículos eléctricos (UTEFING_VE)

La base de datos de vehículos eléctricos consta de medidas agregadas de potencia activa y potencia reactiva cada 15 minutos, así como medidas desagregadas del consumo del cargador del vehículo eléctrico de potencia activa y reactiva, también cada 15 minutos.

Es una base de datos sintética confeccionada en conjunto con el equipo de UTE. Los usuarios de UTE que poseen vehículos eléctricos pueden solicitar tarifas de consumo diferenciadas para sus vehículos, lo que nos permitió inspeccionar el consumo de estos hogares y detectar que nueve de ellos utilizaban su instalación eléctrica exclusivamente para cargar un vehículo. Por lo tanto, contamos con curvas de consumo de potencia activa y reactiva adquiridas por el medidor inteligente cada 15 minutos para estos nueve hogares.

Los nueve usuarios utilizados para recolectar las series de potencia de carga poseen un SAVE (Sistema de Alimentación Específico de Vehículo Eléctrico), el cual se observa que utiliza una potencia de $7,4kW$ para la carga en la mayoría de las oportunidades.

El procedimiento para crear esta base de datos consiste en, para cada serie temporal de la base de termotanques (que es sabido que no posee vehículo eléctrico) seleccionar aleatoriamente una de las nueve series de consumo de solo vehículo eléctrico y sumarla, de forma de obtener una serie sintética. El Algoritmo 1 ilustra este procedimiento. De esta forma se consigue una base de datos sintética con 478

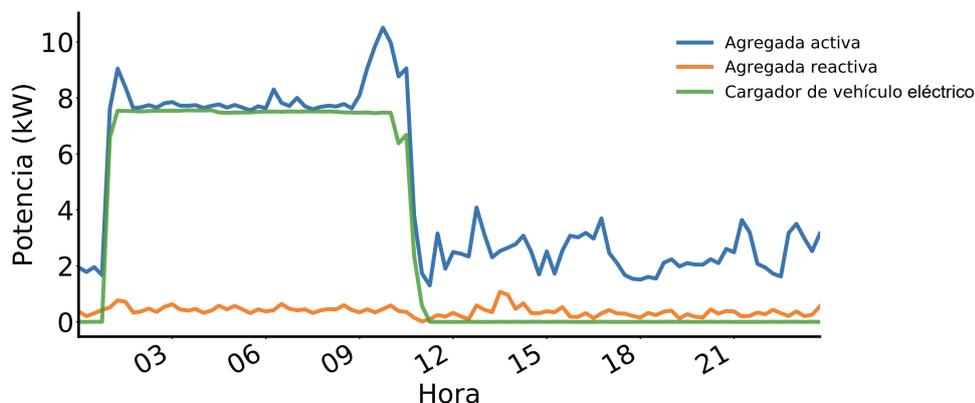


Figura 3.3: Series temporales de consumo para un hogar sintético de la base de datos de vehículos eléctricos en un día en particular.

hogares con 9 tipos distintos de vehículos eléctricos. Notar que por la forma de confeccionar la base, los datos provienen de los medidores Kaifa modelo *MA110P*.

Algoritmo 1 Creación de la base de datos sintética de vehículos eléctricos.

Input: Series agregadas de base de termotanques, series desagregadas de vehículos eléctricos

Output: Series sintéticas

for cada hogar i en la base de termotanques **do**

 Elegir un hogar j al azar de la base de vehículos eléctricos

$s_sintetica[i] \leftarrow s_agregada[i] + s_vehiculo_electronico[j]$

La Figura 3.3 muestra un ejemplo de una serie de consumo sintética de esta base de datos.

3.3.3. Base de datos de aires acondicionados (UTEFING_AA)

La base de datos de aires acondicionados consiste únicamente en medidas desagregadas cada 1 minuto de potencia activa. El proceso de adquisición se inició en el año 2020 y se extiende hasta la actualidad. La recolección de datos se llevó a cabo mediante medidores intrusivos, idénticos a los utilizados para la base de datos de termotanques, como los de la Figura 1.2 del Capítulo 1. Se definió un protocolo de adquisición de los datos y se instalaron medidores en edificios de UTE, en la FING y en casas particulares de miembros del equipo de trabajo.

En total, se han instalado siete medidores en una localidad de UTE, dieciocho en la FING y ocho en casas de integrantes del proyecto. Por lo tanto, esta base de datos incluye tanto hogares residenciales como oficinas.

En la Figura 3.4 se muestra un ejemplo de la curva de consumo desagregada de una oficina en la FING.

Capítulo 3. Generación y preparación de bases de datos

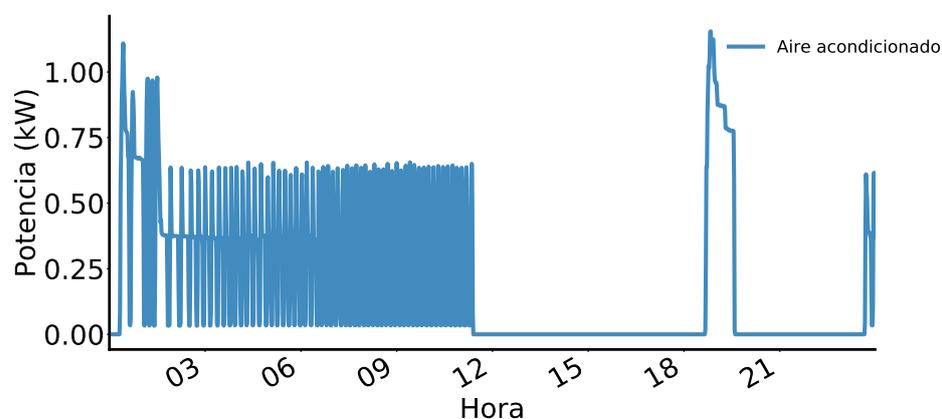


Figura 3.4: Serie temporal de consumo de un aire acondicionado de la base de datos de aires acondicionados en un día en particular.

3.3.4. Base de datos NILM-UY

Esta base de datos fue recolectada en el contexto del proyecto de fin de carrera titulado *Monitoreo no intrusivo de cargas eléctricas (NILM)* [110], en el cual participé. La base de datos fue presentada en un artículo académico de mi autoría [53] y se encuentra publicada en el repositorio: <https://github.com/camilomarinero/NILM-UY>.

La base de datos consiste en mediciones de dos hogares uruguayos durante un período de aproximadamente tres meses, hacia finales del año 2019 y principios de 2020. Se recolectaron mediciones de potencia activa agregada a una frecuencia de 14 kHz, y las mediciones intrusivas tienen un período de 1 minuto. En la primera casa, se midieron siete electrodomésticos: heladera, termotanque, microondas, aire acondicionado, enchufes de propósito general de los dormitorios, lavadora. La segunda casa cuenta con medidas de ocho electrodomésticos: horno eléctrico, termotanque, dos aparatos de aire acondicionado, lavadora, heladera, jarra eléctrica y lavavajillas. Cabe destacar que estos electrodomésticos representan la mayor parte del consumo eléctrico del hogar.

Los datos agregados fueron recolectados mediante una placa de audio conectada a una Raspberry Pi, junto con un circuito acondicionador de las señales. Las señales desagregadas se adquirieron con los medidores Sonoff de la Figura 1.2 del Capítulo 1 suministrados por UTE.

Es importante destacar que la base NILM-UY es la única base de datos uruguaya con una cantidad importante de datos submedidos, y es la única con una frecuencia nominal de 50 Hz y una tensión nominal de 230 V_{RMS} . La disponibilidad de esta base de datos puede ser de gran utilidad para la evaluación de algoritmos de aprendizaje automático y para obtener conocimientos sobre el consumo de energía en hogares uruguayos.

En la Figura 3.5 se muestran las series temporales de los electrodomésticos

3.4. Comparativa de bases de datos

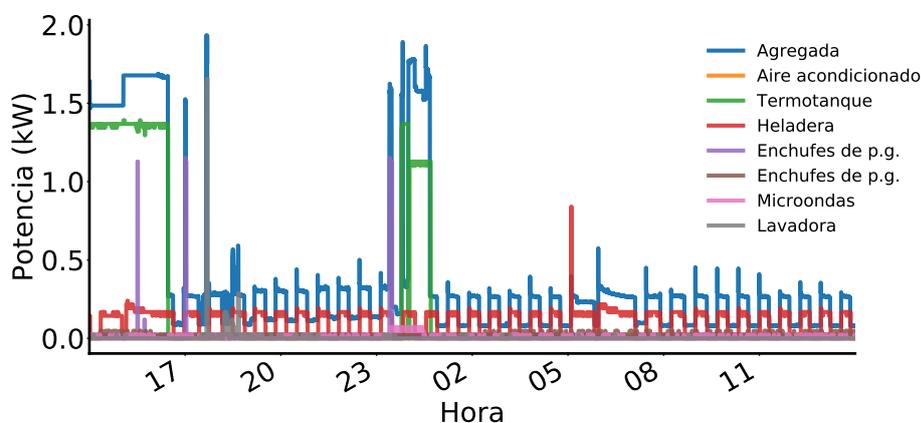


Figura 3.5: Series temporales de consumo de la casa 1 de la base de datos NILM-UY para un día en particular.

medidos en la casa 1 a lo largo de un día. Se puede observar que el consumo predominante, debido a los patrones de consumo de los usuarios de ese hogar, está dado por el termotanque y la heladera.

3.4. Comparativa de bases de datos

La Tabla 3.1 muestra las características principales de las bases de datos públicas y propias utilizadas en este trabajo. Se incluye información sobre su ubicación geográfica, fecha de publicación, número de hogares y número promedio de medidores por hogar. La última columna refleja la cantidad promedio de tiempo, en meses, que se adquirieron datos en cada casa de cada base de datos. Es importante destacar que la base de datos de termotanques recolectó datos en 478 hogares, lo que la convierte en la base con el mayor volumen de datos.

3.5. Formato de almacenamiento y lectura NILMTK-HDF

Las diferentes características de las bases de datos pueden ser en la cantidad de hogares, la frecuencia de muestreo, la duración de la medición, entre otras. No obstante, una de las principales diferencias reside en la manera de almacenar los datos, dado que suele variar significativamente en función del empleo de diferentes sistemas de medición. Esto genera una barrera práctica para el uso de las distintas bases de datos porque conlleva mucho tiempo procesar de forma distinta cada una de ellas.

Para abordar esta problemática, entre otras, se desarrolló la biblioteca NILMTK [111], escrita en Python, la cual provee una solución para la estandarización de formatos de bases de datos, implementando el formato NILMTK-HDF. Consiste en un archivo en formato Hierarchical Data Format (HDF), el cual contiene una

Capítulo 3. Generación y preparación de bases de datos

Nombre	Ubicación	Fecha de publicación	Numero de hogares	Numero de medidores promedio por hogar	Periodo de muestreo	Total de meses promedio por hogar
AMPds	Canada	2013, 2014	1	21	1 min	24.3
COMBED	India	2014	2	10	30 s	0.9
Dataport	Estados Unidos	2015	73	12	1 min	10.1
DEDDIAG	Alemania	2020	1	6	1 s	3.0
DRED	Países Bajos	2015	1	13	1 s	5.1
ECO	Suiza	2014	6	11	1 s	7.4
ENERTALK	Corea del Sur	2019	22	4	15 Hz	2.6
GeLaP	Alemania	2022	20	11	0.28 s - 1 s	5.2
GREEND	Austria-Italia	2014	8	8	1 s	50.6
IDEAL	Reino Unido	2021	39	6	1 s	10.3
iAWE	India	2013	1	12	1-6 s	2.4
MORED-WPILGT	Marruecos	2020	9	5	5 s	2.4
NILM-UY	Uruguay	2021	2	9	14 kHz - 1 min	1.9
RAE	Canada	2017	2	18	1 s	2.0
REDD	Estados Unidos	2011	6	18	15 kHz - 3 s	1.3
REFIT	Reino Unido	2015	20	10	7 s	18.1
SynD	Austria	2019	1	22	5 Hz	6.0
UK-DALE	Reino Unido	2015	5	21	16 kHz - 6 s	13.7
UTEFING_AA	Uruguay	2023	30	1	1 min - 15 min	14.7
UTEFING_AG_TT	Uruguay	2023	478	1	1 min - 15 min	25.5
UTEFING_AG_VE	Uruguay	2023	478	1	1 min - 15 min	19.4

Tabla 3.1: Tabla comparativa de bases de datos.

estructura jerárquica de carpetas con datos y metadatos asociados. Fue diseñado para incluir las series de potencia activa, potencia reactiva, corriente, voltaje, entre otros, así como otros tipos de mediciones como agua, gas y temperatura.

Otra característica importante del formato NILMTK-HDF es la estandarización de la nomenclatura de electrodomésticos y medidas adquiridas. En diferentes bases de datos, puede suceder que los electrodomésticos o las medidas adquiridas se nombren de forma diferente (e.j. “act_power” o “active power”). Para resolver esta problemática, se propuso una taxonomía para nombrar a los electrodomésticos que se describe en [111] y se puede encontrar en https://github.com/nilmmtk/nilm_metadata/tree/master/nilm_metadata/central_metadata/appliance_types.

La estructura interna del archivo HDF se muestra en la Figura 3.6. Cada base de datos (*Dataset*) contiene hogares (*Building*), los cuales poseen electrodomésticos (*Appliance*) y medidores (*ElecMeter*) con sus respectivas medidas o datos propiamente dichos (*Measurment*).

Para acceder al archivo NILMTK-HDF se puede utilizar cualquier biblioteca de manejo de archivos HDF. Sin embargo, la biblioteca NILMTK ha definido una API que, junto con la definición de la estructura de datos en memoria del formato NILMTK-HDF, permite sistematizar el análisis en múltiples bases de datos en conjunto acelerando el tiempo de desarrollo.

La gran ventaja de utilizar NILMTK-HDF es que se pueden implementar algoritmos lo suficientemente genéricos e independientes de la base de datos de electrodomésticos que se utilice. La Figura 3.7 ilustra el flujo para utilizar este tipo de base de datos, permitiendo centrarse en el desarrollo de algoritmos y en la evaluación de su capacidad de generalización a través de diferentes bases de datos.

La forma habitual de distribuir una base de datos en esta área es proporcionar los datos crudos obtenidos con el sistema de medición utilizado, junto con un

3.6. Convertidores NILMTK-HDF implementados

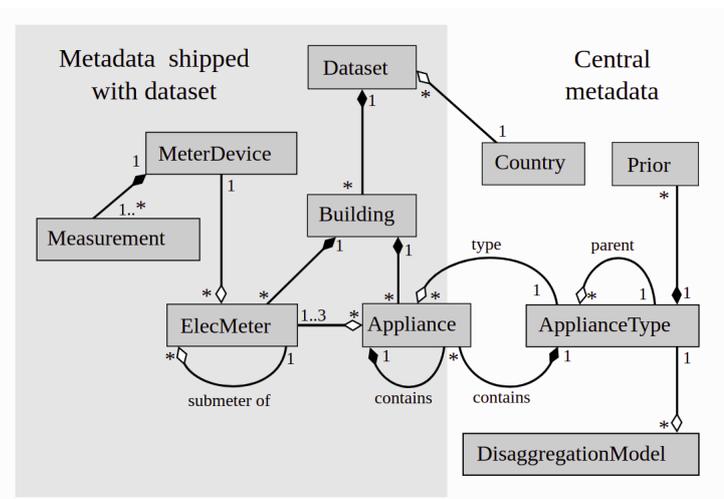


Figura 3.6: Diagrama UML de las relaciones de los distintos objetos que interactúan en una base de datos NILM. Por más detalle ir a: <https://nilm-metadata.readthedocs.io/en/latest/tutorial.html>

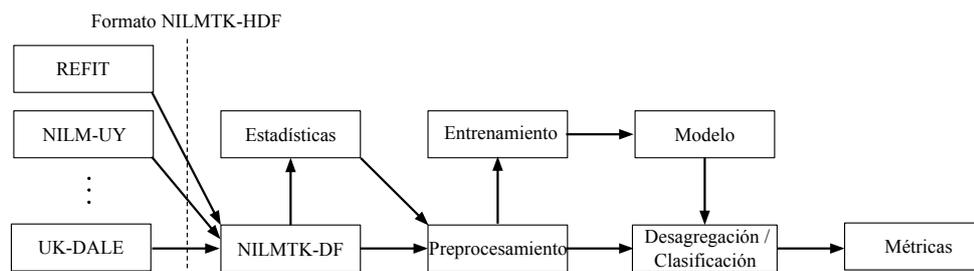


Figura 3.7: Flujo de trabajo partiendo de una base de datos en formato NILMTK-HDF.

código Python que, haciendo uso de NILMTK, genere el archivo NILMTK-HDF correspondiente. En la actualidad, existen al menos 16 bases de datos distribuidas de esta manera y los *scripts* de conversión están disponibles de forma abierta en https://github.com/nilmtk/nilmtk/tree/master/nilmtk/dataset_converters.

Por último, cabe mencionar que las bases de datos públicas descritas en la Sección 3.2 fueron escogidas por poseer un convertidor al formato NILMTK-HDF.

3.6. Convertidores NILMTK-HDF implementados

Durante el proceso de conversión de las bases de datos, se identificaron ciertos convertidores implementados en la biblioteca NILMTK que presentaban errores, lo que dificultaba la conversión de dichas bases de datos. Además, se detectaron bases de datos recientes que podrían aportar variedad a las bases existentes, pero no se suministraron con un convertidor a NILMTK-HDF.

En esta sección, se detallan los convertidores implementados para las bases de datos recientes que fueron proporcionadas sin un convertidor, así como los con-

Capítulo 3. Generación y preparación de bases de datos

vertidores para las bases de datos propias recolectadas en colaboración con UTE. Además, se exponen las correcciones realizadas a los convertidores disponibles que presentaban errores.

Con el objetivo de hacer que estos aportes sean accesibles y útiles para otros usuarios, las implementaciones de los nuevos convertidores se han compartido en repositorios públicos de GitHub, y las correcciones de errores se han realizado mediante Pull Requests en el repositorio de la biblioteca NILMTK.

3.6.1. GREEND

El convertidor de la base de datos GREEND presentaba errores en su script de conversión, lo que impedía la adecuada transformación de los datos en formato original a NILMTK-HDF. Para corregir esta situación, se realizó una *Pull Request* en el repositorio oficial de la biblioteca NILMTK <https://github.com/nilmtk/nilmtk/pull/946> que soluciona el error.

3.6.2. RAE

Al igual que en el caso anterior, el convertidor de la base de datos RAE presente en la biblioteca NILMTK contenía errores en su script de conversión, lo que dificultaba la adecuada transformación de los datos en formato original a NILMTK-HDF. Para solucionar esta situación, se realizó una *Pull Request* en el repositorio oficial de NILMTK <https://github.com/nilmtk/nilmtk/pull/947> que soluciona el error.

3.6.3. ENERTALK

Aunque el convertidor de la base de datos ENERTALK no se encuentra en el repositorio oficial de NILMTK, su script de conversión es público y se encuentra en un repositorio externo. En este caso, también se detectó un error en el script de conversión que impedía la adecuada transformación de los datos al formato NILMTK-HDF. Para solucionar este problema, se realizó una *Pull Request* en el repositorio externo <https://github.com/ch-shin/ENERTALK-dataset/pull/35> que soluciona el error.

3.6.4. NILM-UY

En el repositorio de GitHub <https://github.com/camilomarino/NILM-UY-Dataset> se encuentra el convertidor de la base de datos NILM-UY a formato NILMTK-HDF. Este recurso es un aporte importante ya que permite a los investigadores utilizar una base de datos de origen uruguayo. Además, la disponibilidad de esta base de datos en un formato unificado facilita la comparación entre algoritmos y evaluar su capacidad de generalización.

3.7. Descripción de patrones de consumo de electrodomésticos

3.6.5. GeLap

La base de datos GeLap se encuentra disponible públicamente, pero no en formato NILMTK-HDF. En el repositorio de GitHub <https://github.com/camilomarino/GeLaP-NILMTK-Converter> se proporciona el código correspondiente para convertir esta base de datos a formato NILMTK-HDF. La elección de esta base de datos se debe a que es relativamente reciente, del año 2020, y es de una región de la cual la comunidad científica no cuenta con muchos datos.

3.6.6. MORED

La base de datos MORED fue publicada sin convertidor a formato NILMTK-HDF. En el repositorio de GitHub <https://github.com/camilomarino/MORED-NILMTK-Converter> se proporciona el código correspondiente para realizar esta conversión. La elección de esta base de datos se debe a que es relativamente reciente, tiene medidas hasta el año 2022, y es de origen africano, siendo la única de esta región hasta el momento disponible para la comunidad científica.

3.6.7. UTEFING_TT, UTEFING_VE y UTEFING_AA

En este trabajo, la elaboración de los convertidores para las bases de datos UTEFING_TT, UTEFING_VE y UTEFING_AA representó un desafío considerable en términos de tiempo. La implementación de estos convertidores demandó una colaboración estrecha con el equipo técnico de UTE encargado de la extracción de los datos. Durante el proceso, se realizaron varias reuniones para profundizar en el almacenamiento de los datos [106] mediante MongoDB/HBASE y determinar la forma más adecuada para compartir la información.

Después de un análisis detallado, se estableció el protocolo de transferencia de datos a ser utilizado, el cual se presenta en la Figura 3.8. El protocolo se basó en tener un archivo CSV por cada hogar para los datos agregados (*id_Punto_Servicio*) y un CSV por cada electrodoméstico (ya sea un termotanque o aire acondicionado), así como un CSV con la metadata correspondiente a cada hogar y electrodoméstico.

Una vez que se recibieron los datos de acuerdo con el protocolo establecido, se procedió a implementar los convertidores de cada una de las bases de datos (termotanques, aires acondicionados y vehículos eléctricos) al formato NILMTK-HDF. Debido a que los datos de UTE no son públicos, el conversor también se mantiene de forma privada.

3.7. Descripción de patrones de consumo de electrodomésticos

A fin de obtener una comprensión más profunda de los algoritmos de aprendizaje automático aplicados en ILM y NILM sobre las bases de datos presentadas, resulta fundamental familiarizarse con las características y patrones de los datos que contienen. Por ello, en esta sección se describen de manera general los patrones

Capítulo 3. Generación y preparación de bases de datos

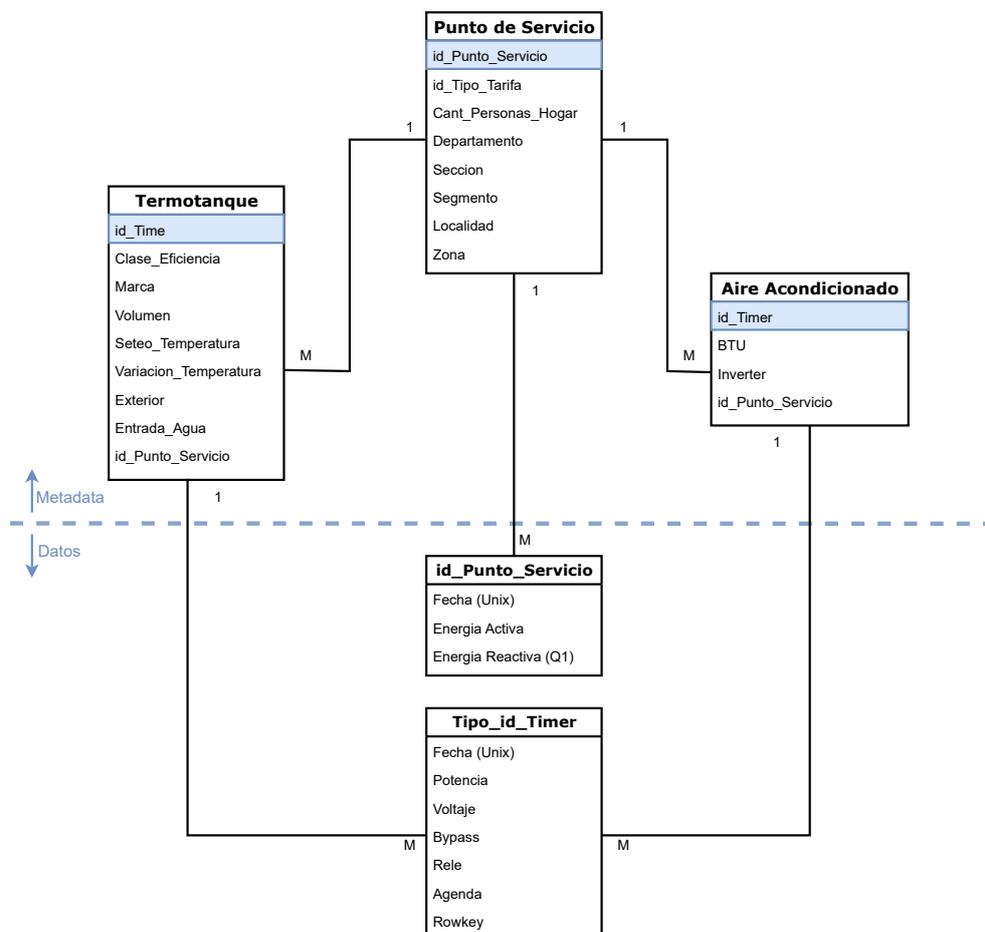


Figura 3.8: Esquema del protocolo de transferencia de datos acordado entre el grupo FING y UTE. Cada entidad (rectángulo) es un archivo CSV y los elementos enumerados dentro de este son las columnas del CSV.

de consumo de los electrodomésticos y, posteriormente, se examinan los patrones de dos dispositivos de interés: el termostanque y el vehículo eléctrico.

3.7.1. Categorización en tiempo corto

En varios trabajos [2, 3, 112, 113] se suele categorizar a los electrodomésticos, según su patrón de consumo en tiempo corto (también llamado firma o huella), en cuatro grupos.

El primer grupo, Tipo-1 o **ON-OFF**, lo componen los electrodomésticos de consumo constante. Son dispositivos de dos estados que, cuando están encendidos, consumen siempre la misma cantidad de energía. En este grupo se encuentran heladeras, lámparas, jarras eléctricas, termostanques, dispositivos puramente resistivos, entre otros. Estos dispositivos son relativamente fáciles de identificar si se tiene claro cuál es su consumo. Sin embargo, la detección de electrodomésticos de Tipo-1 puede ser más difícil cuando hay varios de ellos con consumo similar. En

3.7. Descripción de patrones de consumo de electrodomésticos

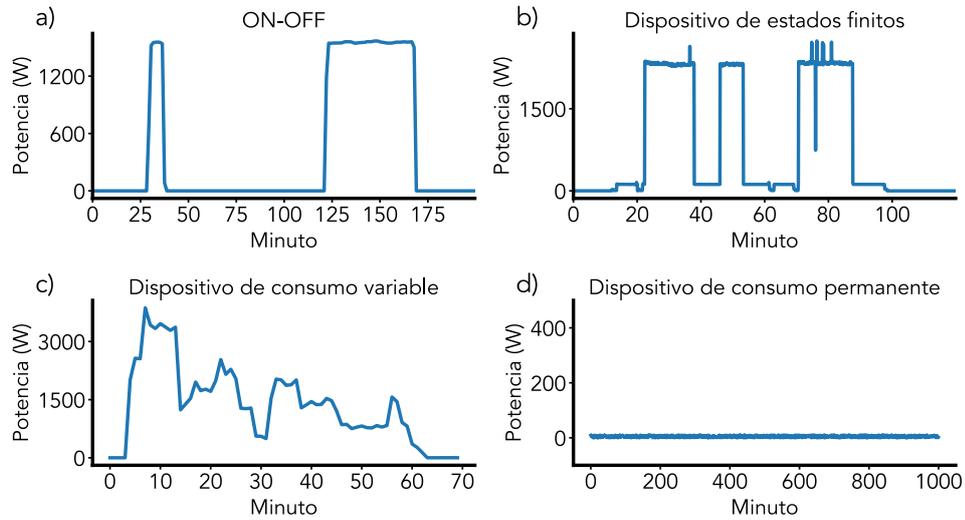


Figura 3.9: Ejemplos de los distintos tipos de electrodomésticos. a) ON-OFF. b) Máquina de estado finita. c) Dispositivo de consumo variable. d) Dispositivo de consumo permanente

la Figura 3.9.a se muestra, como ejemplo, el consumo de un termotanque.

El segundo grupo, Tipo-2 o **Dispositivos de Estados Finitos**, está compuesto por los aparatos con múltiples modos de operación, pero que consumen un valor de potencia constante en cada estado. Por ejemplo, el lavavajillas de la Figura 3.9.b tiene tres modos de funcionamiento: apagado, encendido con bajo consumo y encendido con alto consumo. Otros electrodomésticos de Tipo-2 son los lavarropas. Este grupo también incluye aquellos que son operados por el usuario, como los ventiladores de varios niveles de intensidad, que para cada uno de los niveles consumen una potencia distinta. La detección de electrodomésticos de Tipo-2 puede ser más compleja que la de Tipo-1.

El tercer grupo, Tipo-3 o **Dispositivos de Consumo Variable**, incluye a los electrodomésticos que o bien no tienen estados o que su consumo fluctúa cuasi-aleatoriamente como en la Figura 3.9.c. También incluye dispositivos que pueden tener estados, pero cuyo consumo de potencia no es constante, así como a los dispositivos ajustables a granularidad fina, como atenuadores de luz. Este tipo de electrodomésticos suele ser el más difícil de detectar mediante algoritmos de aprendizaje automático dado que su curva de consumo es impredecible.

El último grupo, Tipo-4 o **Dispositivo de Consumo Permanente**, lo componen los electrodomésticos que siempre están encendidos consumiendo un valor constante de energía. Ejemplos de estos son canaleras digitales o módems de internet. Suelen ser difíciles de detectar en consumos agregados ya que solo introducen un offset en el consumo total. Sin embargo, no suelen entorpecer la tarea de detección de otros electrodomésticos.

3.7.2. Categorización en tiempo largo

La categorización en tiempo largo se enfoca en patrones de consumo a una escala más macro, analizando los consumos a lo largo de varias horas e incluso días, y no concentrándose únicamente en las formas de las curvas. Esta categorización divide a los electrodomésticos en dos grupos.

El primer grupo, **Dispositivos no Comandados por el Usuario**, incluye a aquellos electrodomésticos que no requieren la intervención de un usuario para su funcionamiento. La heladera es un claro ejemplo de este tipo de dispositivo, que sigue un patrón de encendido y apagado a lo largo del día de manera periódica, como se observa en la Figura 3.10.b, aunque estrictamente este último no es un electrodoméstico periódico, ya que los tiempos en los que está encendido dependen de otros factores como la temperatura ambiente y la frecuencia de apertura de la heladera. Otros dispositivos, como el termotanque, bajo ciertas circunstancias, que se verán luego, pueden ser incluidos en este grupo, ya que suelen tener patrones de encendido y apagado constantes a lo largo del día, similar a los de la heladera. En otras palabras, estos dispositivos están encendidos todo el día y su consumo varía según sus necesidades autodeterminadas sin la intervención de un usuario externo. Los Dispositivos de Consumo Permanente también son parte de este grupo.

El otro grupo, los **Dispositivos Comandados por el Usuario**, está compuesto por los electrodomésticos que requieren que una persona los encienda voluntariamente para que comiencen a consumir energía. La mayoría de los electrodomésticos de un hogar pertenecen a este grupo, como el horno, el microondas, el televisor, entre otros. Al observarlos en tiempo largo, se incorporan los patrones del usuario que acciona el electrodoméstico. Esto significa que los algoritmos de aprendizaje automático pueden hacer uso de esta información y aprender no solo de las formas de las curvas en tiempo corto, sino también del comportamiento del usuario. Por ejemplo, no es de esperarse que el horno eléctrico se encienda en la madrugada, y es común que el microondas se encienda cercano a la hora del almuerzo. En los últimos tiempos existe una tendencia en comandar incluso a los electrodomésticos que solían ser del primer grupo, para así ahorrar energía. Por ejemplo, UTE con los medidores de la Figura 1.2 del Capítulo 1 tiene el permiso de los usuarios para comandar el termotanque, siendo capaz de apagarlo en las horas que el Ente estime que habrá alta demanda de energía por parte de la población. En el caso anterior el termotanque se transforma en un dispositivo híbrido, siendo comandado por tramos.

La Figura 3.10 muestra el ejemplo de curvas de consumos de ambos grupos en un hogar de Uruguay. A la izquierda la curva de un aire acondicionado comandado, el cual fue encendido en distintas oportunidades, mientras que a la derecha la curva de potencia periódica de una heladera.

3.7.3. Patrones de consumo del termotanque

El termotanque es un dispositivo ON-OFF y por lo general no es comandado por el usuario. Sin embargo, esto último no siempre es así, además de lo ya mencionado de que UTE comanda termotanques de algunos clientes, algunos usuarios

3.7. Descripción de patrones de consumo de electrodomésticos

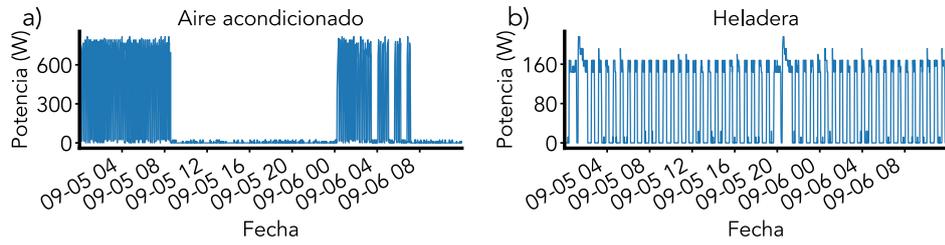


Figura 3.10: Ejemplos de los distintos tipos de electrodomésticos en tiempo largo. Ambas curvas son extraídas en el mismo periodo de tiempo, de un día y medio, de la base NILM-UY.

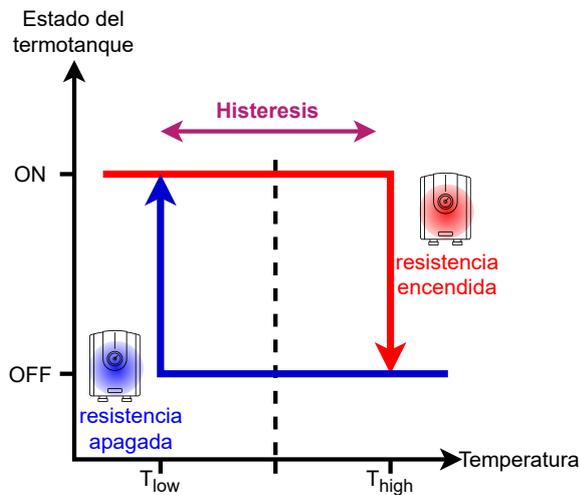


Figura 3.11: Ciclo de histéresis de un termotanque para calentar agua.

suelen comandar ellos mismos el termotanque, por ejemplo encendiéndolo poco tiempo antes de utilizar agua caliente.

A grandes rasgos, un termotanque es una gran resistencia capaz de calentar agua junto con un sensor de temperatura para el agua. Es un electrodoméstico puramente resistivo, por lo que solo consume potencia activa a un valor constante. La Figura 3.11 presenta el modo de funcionamiento básico que consiste en encenderse cuando el agua presenta una temperatura inferior a T_{low} y apagarse cuando la temperatura sobrepase T_{high} , siguiendo un ciclo de histéresis.

Por lo tanto, un termotanque se caracteriza por los valores de su resistencia, cantidad de agua que almacena, T_{low} y T_{high} . Estos en conjunto determinan el tiempo que requiere en enfriarse y calentarse el agua, en otras palabras, el *Duty Cycle*. Existen factores externos que influyen en estos tiempos, como ser la temperatura ambiente o fallas en el aparato. Sin embargo, la principal causa que modifica estos tiempos es el uso por parte del usuario del termotanque, lo cual disminuye el tiempo requerido para tener que volver a calentar el agua. Es normal, que pocos instantes después de ser utilizado, la temperatura del agua disminuya rápidamente requiriendo que se encienda la resistencia interna. De no existir usos,

Capítulo 3. Generación y preparación de bases de datos

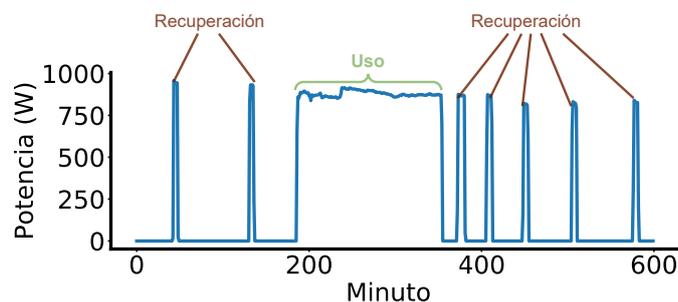


Figura 3.12: Estados de un termostato.

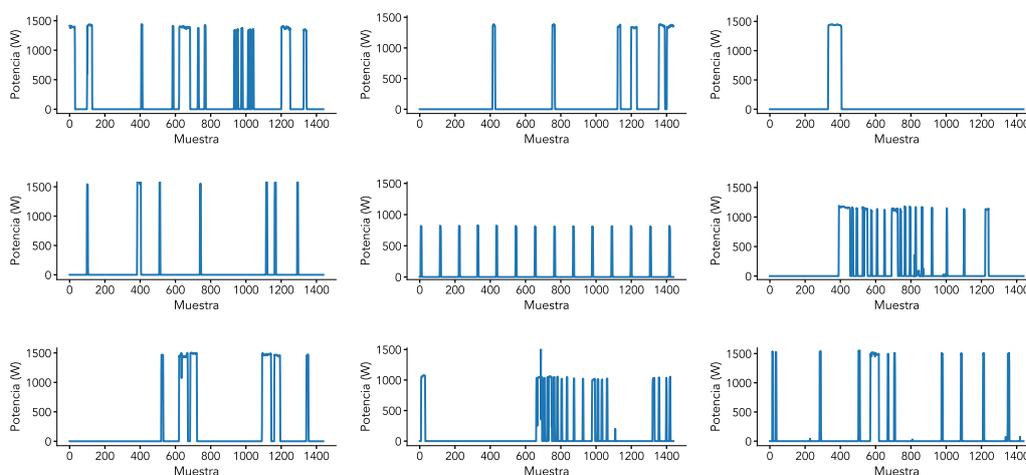


Figura 3.13: Series temporales de consumo de termostatos a lo largo de un día de la base de datos UTEFING_TT con una muestra por minuto.

el termostato presentaría un consumo periódico.

En la jerga se suele decir que un termostato puede estar en tres estados: **apagado**, encendido por **uso** o encendido por **recuperación**. El primero es, como su nombre indica, cuando el termostato está apagado. Por otro lado, las otras dos condiciones se refieren a cuando el termostato está encendido, y su diferencia radica en la causa que provocó el encendido. Si el termostato se encendió debido a que un usuario utilizó agua caliente, se denomina **uso**; en cambio, si se encendió por el proceso natural de perder temperatura, se llama **recuperación**. En la Figura 3.12 se muestra un ejemplo de un termostato que pasa por los tres estados, indicando cada uno de ellos. Es importante destacar que los eventos de uso suelen tener una duración más larga que las recuperaciones.

Por último, con el objetivo de ganar intuición acerca de cómo se ven las curvas de consumo de termostatos, en la Figura 3.13 se presentan varios ejemplos del consumo de un termostato a lo largo de un día (desde las 00:00 hasta las 24:00). Se puede observar variabilidad en diversas características, como la potencia o duración de las recuperaciones. También se aprecia que algunos termostatos están controlados y otros permanecen encendidos durante todo el día.

3.7. Descripción de patrones de consumo de electrodomésticos

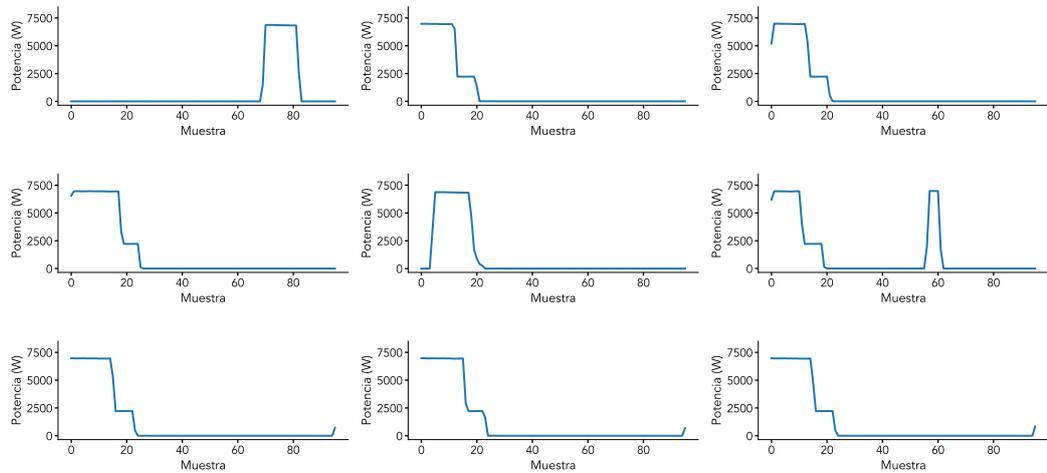


Figura 3.14: Series temporales de consumo de vehículos eléctricos a lo largo de un día de la base de datos UTEFING_VE. Una muestra cada 15 minutos.

3.7.4. Patrones de consumo del vehículo eléctrico

El patrón de consumo de vehículos eléctricos se caracteriza por ser ON-OFF, y son dispositivos que son comandados por el usuario, lo que significa que el momento en el cual se realiza la carga está sujeto a las preferencias del usuario.

A pesar de la diversidad de vehículos y cargadores disponibles, aquí nos centraremos en los patrones de consumo de los vehículos incluidos en la base de datos UTEFING_VE, ya que son los datos a los que se tiene acceso. En estos registros, se observa el uso de cargadores SAVE que proporcionan una potencia en estado ON de 7,4 kW durante algunas horas.

La Figura 3.14 muestra las curvas de consumo de vehículos eléctricos a lo largo de un día en la base de datos UTEFING_VE. Es posible apreciar que, cuando el vehículo está en proceso de carga (ON), el consumo alcanza valores cercanos a 7,4 kW. En algunos casos, al final del ciclo de carga, el consumo se reduce a aproximadamente a 2,4 kW, lo que transforma al dispositivo en uno de 2 estados ON. Con respecto a los patrones a largo plazo, lo habitual es realizar una carga diaria, con una duración de entre 4 y 6 horas, usualmente durante la noche o la madrugada.

3.7.5. Patrones a distinta escala temporal

En las secciones previas, se explicaron los patrones de consumo de electrodomésticos sin prestar demasiada atención a las tasas de muestreo en las que se adquirieron los datos. Sin embargo, la modificación de la tasa de muestreo puede tener un impacto significativo en los patrones que presentan.

La Figura 3.15 muestra cómo cambian las curvas de consumo al disminuir la tasa de muestreo desde 1 minuto hasta 60 minutos. Por ejemplo, se puede observar cómo el termotanque pasa de ser un electrodoméstico ON-OFF a parecerse a

Capítulo 3. Generación y preparación de bases de datos

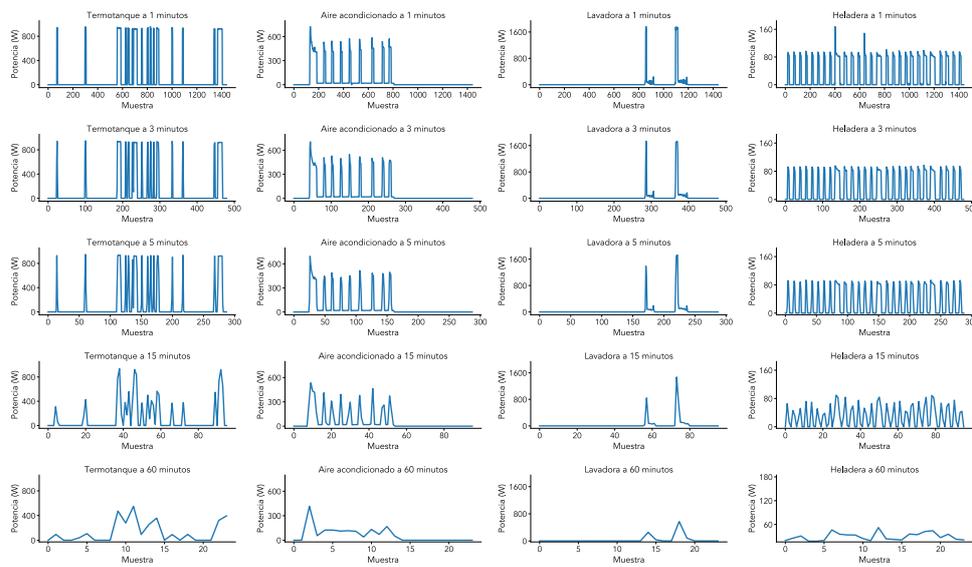


Figura 3.15: Series temporales de termostaque, aire acondicionado, lavadora y heladera vistos a cuatro tasas de muestreo diferente. Cada columna corresponde a la misma curva de consumo a distinta tasa.

un dispositivo de consumo variable, ocurriendo lo mismo con los demás electrodomésticos. Se nota que a tasa de 60 minutos, los electrodomésticos son difícilmente distinguibles a simple vista y casi no siguen patrones evidentes.

Por lo tanto, trabajar a tasas de muestreo lentas representa un gran desafío, tema que se abordará en los capítulos restantes de este documento.

Capítulo 4

Identificación intrusiva del tipo de electrodoméstico

En este capítulo se aborda el problema de identificar si una serie temporal corresponde o no a un electrodoméstico específico. Se propone un enfoque basado en el desarrollo de clasificadores multiclase utilizando redes neuronales. Además, se evalúa el rendimiento de los algoritmos a diferentes tasas de muestreo.

4.1. Definición del problema

El objetivo de este capítulo es identificar a qué tipo de electrodoméstico pertenece una serie temporal de consumo de potencia activa, con énfasis en el termotanque. Se trata de un problema ILM de clasificación multiclase sobre series temporales, donde el objetivo es asignar una etiqueta correspondiente al tipo de electrodoméstico.

Por otro lado, dada la relevancia de los termotanques en Uruguay, existe un interés especial en identificarlos. En este caso, se trata de un problema de clasificación binaria en el que el objetivo es asignar una etiqueta “termotanque” o “no-termotanque” a cada una de las series de consumo. No obstante, se puede tratar al problema binario como un subproblema de la clasificación multiclase. En la Figura 4.1 se muestra el esquema de clasificación multiclase y binaria.

4.2. DL-ILM: Deep Learning para ILM

En esta sección se presentan y describen las etapas para implementar los algoritmos de clasificación en series temporales de consumo eléctrico. La Figura 4.2 ilustra el flujo de trabajo que se divide en cuatro etapas, las primeras tres correspondientes a la recolección y tratamiento de datos para entrenar los algoritmos de clasificación y la última al entrenamiento del algoritmo.

Capítulo 4. Identificación intrusiva del tipo de electrodoméstico

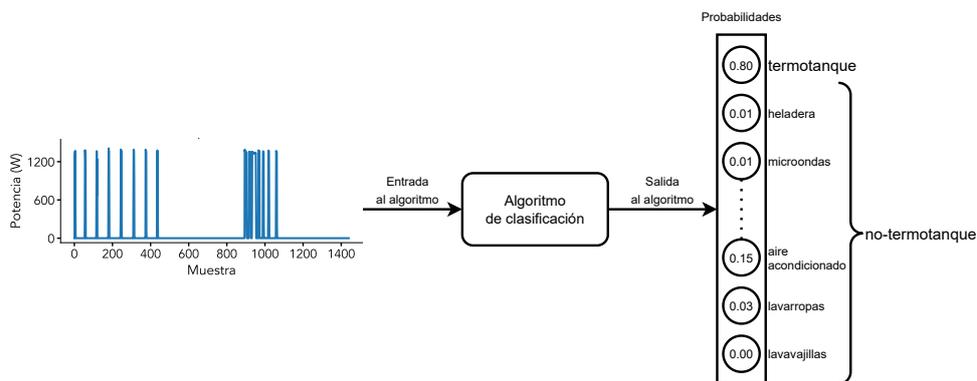


Figura 4.1: Esquema del algoritmo de clasificación de electrodomésticos con énfasis en la clasificación de termotanques.

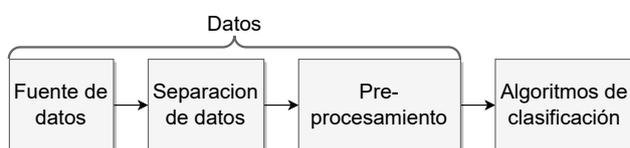


Figura 4.2: Etapas para implementar el algoritmo de clasificación.

4.2.1. Datos

4.2.1.1. Fuente de datos

Para el entrenamiento de los algoritmos de clasificación, se emplearon **todas las bases de datos** mencionadas en el Capítulo 3. Específicamente, se utilizaron únicamente las series temporales de potencia activa **desagregada**, para las cuales se cuenta con una etiqueta asociada a su respectivo tipo de electrodomésticos. La cantidad de tipos distintos de electrodomésticos que proporcionaba cada base de datos se presentó en la Tabla 3.1 del Capítulo 3.4.

La inclusión de varias fuentes de datos de diferentes procedencias busca equilibrar la cantidad de datos de no-termotanques con los de termotanques. Es decir, el objetivo es recolectar la suficiente cantidad de datos con etiquetas no-termotanque para balancear el entrenamiento. Además, el tener datos etiquetados con una granularidad mayor, frente a solo tener una etiqueta “termotanque” o “no-termotanque”, permite entrenar algoritmos de clasificación multiclase.

La utilización de múltiples bases de datos agrega diversidad en los patrones de consumo de electrodomésticos. Al tener acceso a series temporales de electrodomésticos utilizados en diferentes regiones, se aumenta la variabilidad en los datos y se evita el ajuste excesivo a patrones de uso de una región en particular. De esta forma, se logra una mayor generalización del modelo, lo que puede mejorar su desempeño en la clasificación de nuevos datos. Además, al disponer de una mayor cantidad de datos de entrenamiento, se favorece el rendimiento de los algoritmos de aprendizaje automático.

4.2. DL-ILM: Deep Learning para ILM

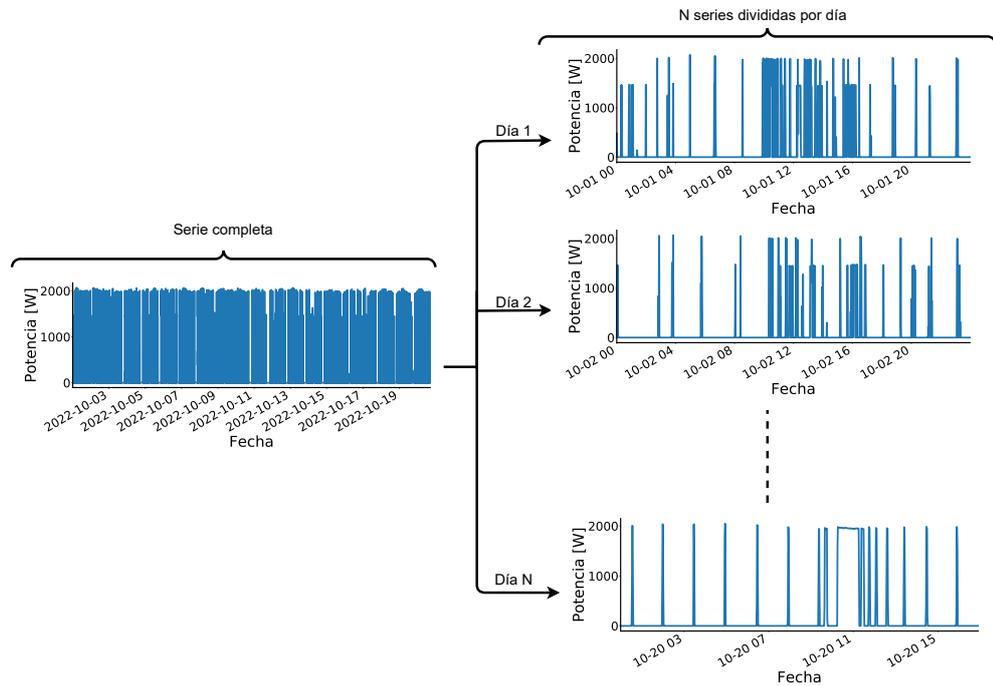


Figura 4.3: Esquema de separación diaria de datos para clasificación.

4.2.1.2. Separación de datos

En esta etapa se dividen las series temporales de varios meses o años en tramos más pequeños de tamaño fijo, que se utilizarán como entrada para los algoritmos de clasificación. Para esto, se dividen las series temporales diariamente, desde las 00:00 horas hasta las 23:59 horas. La Figura 4.3 muestra esquemáticamente este procedimiento.

Esta elección es un aspecto innovador en el abordaje de ILM a muy bajas frecuencias, ya que lo usual en otros trabajos es dividir las series en tramos más cortos. Sin embargo, a muy baja frecuencia con tramos cortos los electrodomésticos presentan una forma de consumo similar, lo que dificulta esta tarea. La utilización de una ventana diaria permite que los algoritmos implementados presten atención tanto al patrón de tiempo corto como al patrón de tiempo largo que el usuario impone al usar el electrodoméstico. Con la ventana diaria se busca que los algoritmos adquieran contexto del patrón diario que suele presentar el usuario, tal como la cantidad de encendidos por día, los horarios de uso, entre otros.

4.2.1.3. Pre-procesamiento de datos

Re-muestreo de las señales: El pre-procesamiento de los datos implica re-muestrear las señales a una tasa de una muestra por minuto. Esto se realiza porque las bases de datos utilizadas tienen diferentes tasas de muestreo (ver Tabla 3.1).

También se re-muestran todos los datos a otras tasas de muestreo, en particular a todos los divisores de 1440 (la cantidad de minutos en un día). Es decir, se

Capítulo 4. Identificación intrusiva del tipo de electrodoméstico

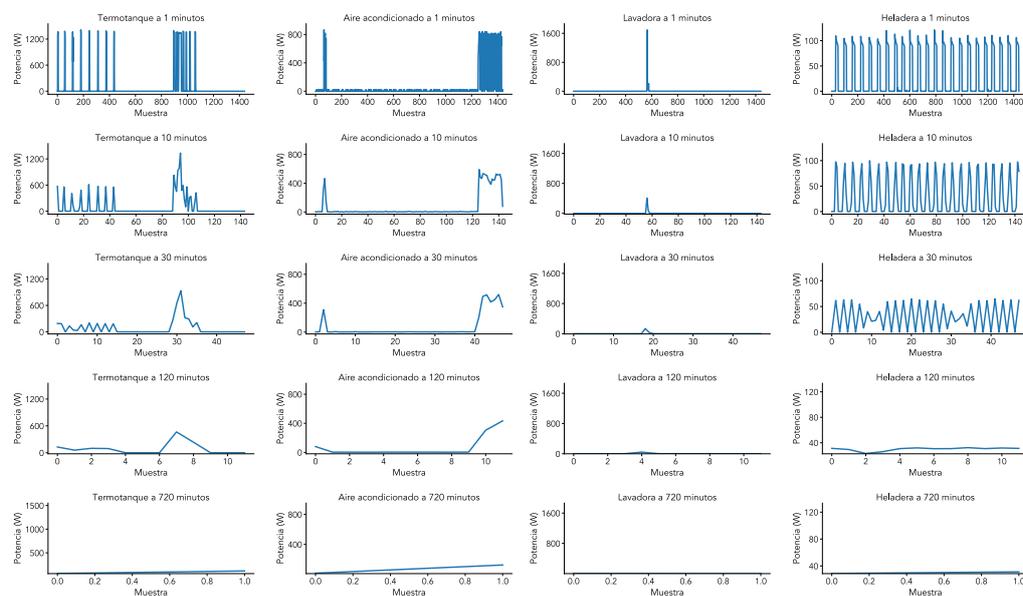


Figura 4.4: Series temporales de termostaque, aire acondicionado, lavadora y heladera re-muestradas a tasas de muestreo diferente. Cada columna corresponde a la misma curva de consumo a distinta tasa.

re-muestra a tasas de 1, 2, 3, 4, ..., 480, 720 y 1440 minutos. Para sub-muestrear el criterio escogido fue dividir cada una de las series en intervalos y asignarle el valor de potencia correspondiente a la media de los valores en el intervalo. En la Figura 4.4 se aprecian series temporales vistas a distintas escalas.

En el Capítulo 3.7.5 se explicó que modificar la tasa de muestreo puede alterar significativamente el patrón de consumo de los electrodomésticos. Tal como se puede observar en la Figura 4.4, el termostaque pasa de tener un patrón ON-OFF a convertirse en un dispositivo con un patrón poco reconocible a tasas más lentas. Por esta razón, resulta de gran interés analizar cómo se comportan los algoritmos al trabajar a frecuencias bajas.

Limpieza de datos: Es importante realizar una verificación de la calidad de los datos y eliminar aquellos que presenten errores de adquisición. En este sentido, se eliminan las series temporales que no contienen todas las mediciones a lo largo del día.

Por otra parte, se descartan las series temporales de los días en que el electrodoméstico no se encendió. Para ello, se utiliza como criterio descartar aquellas series cuyo consumo pico sea menor a $50W$.

4.2.1.4. Conjunto de datos de entrenamiento, validación y test

Es fundamental garantizar que la división del conjunto de datos en entrenamiento, validación y test se realice de manera adecuada para evitar la inclusión de series temporales del mismo electrodoméstico en más de un conjunto simultánea-

4.2. DL-ILM: Deep Learning para ILM

mente, lo que llevaría a un sobreajuste del modelo y una evaluación optimista del rendimiento.

Para garantizar que las series temporales correspondientes a un mismo electrodoméstico no aparezcan en más de un conjunto, se llevó a cabo la división por electrodoméstico. De manera específica, se asignó el 70 % de los electrodomésticos al conjunto de entrenamiento, el 15 % al conjunto de validación y el 15 % restante al conjunto de prueba.

4.2.1.5. Normalización de los datos

La normalización es un paso crucial en el pre-procesamiento de datos, ya que permite que el modelo aprenda de manera más eficiente. En este sentido, se normalizaron las series temporales de potencia activa mediante la utilización de la media y la varianza calculadas sobre el conjunto de entrenamiento. Para ello, se aplicó la siguiente fórmula:

$$P_{elec.norm} = \frac{P_{elec} - \mu_{train}(P_{elec})}{\sigma_{train}(P_{elec})}.$$

Para evitar la filtración de información de los conjuntos de validación y test, la normalización de todos los conjuntos se lleva a cabo utilizando la media y varianza calculadas para el conjunto de entrenamiento.

4.2.1.6. Aumento de datos

El aumento de datos es una técnica que permite generar variantes de los datos existentes a partir de los datos originales, lo que ayuda a evitar el sobreajuste y aumenta la generalización del modelo.

En primer lugar, se utilizó la técnica de multiplicación por un número aleatorio cercano a 1, generándose de esa manera una nueva serie temporal con una escala de potencia levemente distinta.

En segundo lugar, se utilizó la técnica de rotación circular para modificar levemente la hora de las series temporales. Esta técnica consiste en desplazar los puntos de la serie temporal en un número aleatorio de posiciones y en ajustar el índice de tiempo para mantener la coherencia temporal.

En tercer lugar, se aplicaron las técnicas de RandomCrop y RandomDrop para poner la potencia a cero en un tramo contiguo aleatorio de la serie temporal. Esto se obtiene mediante la selección aleatoria de un punto de inicio y un punto final dentro de la serie temporal, para posteriormente establecer la potencia a cero en ese rango.

Por último, se agregó ruido gaussiano a los datos para aumentar la variabilidad y el rango de los datos. Esto se logra mediante la generación de una distribución normal con media y desviación estándar específicas, y luego sumando ese ruido a cada punto de la serie temporal.

Para aplicar estas transformaciones se implementó una biblioteca de propósito general para aumento de datos en series de tiempo en <https://github.com/camilom>

Capítulo 4. Identificación intrusiva del tipo de electrodoméstico

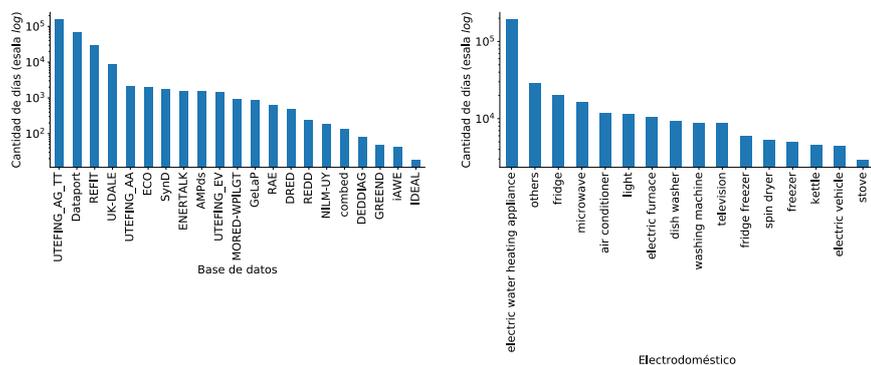


Figura 4.5: Gráfico de barras de la cantidad de datos por base de datos y por tipo de electrodoméstico (manteniendo los nombres de la taxonomía de NILMTK-HDF).

arino/transforms_1d_torch. A continuación se muestra el código correspondiente a la implementación de estas técnicas de aumento de datos:

```
from transforms_1d_torch import transforms1d
transforms1d.Compose(
    [
        transforms1d.Multiply(),
        transforms1d.CircularShift1d(),
        transforms1d.RandomCrop(crop_percentage=0.2),
        transforms1d.RandomDrop(drop_percentage=0.2),
        transforms1d.GaussianNoise(),
    ]
)
```

Esta etapa de pre-procesamiento se realiza en tiempo real, es decir, en el momento en que se toma un dato para entrenar. Esto significa que no se pre-calculan las nuevas series temporales de antemano, sino que se calculan en el momento del entrenamiento.

4.2.1.7. Cantidad de datos por electrodoméstico

Cada serie temporal está asociada a una etiqueta que identifica un electrodoméstico específico de entre todos los posibles presentes en la taxonomía propuesta en NILMTK-HDF, la cual se menciona en el Capítulo 3.5. El uso de esta taxonomía tiene la ventaja de que está estandarizada entre todas las bases de datos utilizadas por lo que no hay que preocuparse por terminologías distintas entre las bases de datos.

El volumen de datos disponible para la implementación de los algoritmos, se puede observar en la Figura 4.5. En particular, se muestra la cantidad que aporta cada base de datos y la cantidad de electrodomésticos por tipo.

Es importante destacar que la cantidad de datos de termotanques es considerablemente mayor en comparación con cualquier otro electrodoméstico, notar la

4.2. DL-ILM: Deep Learning para ILM

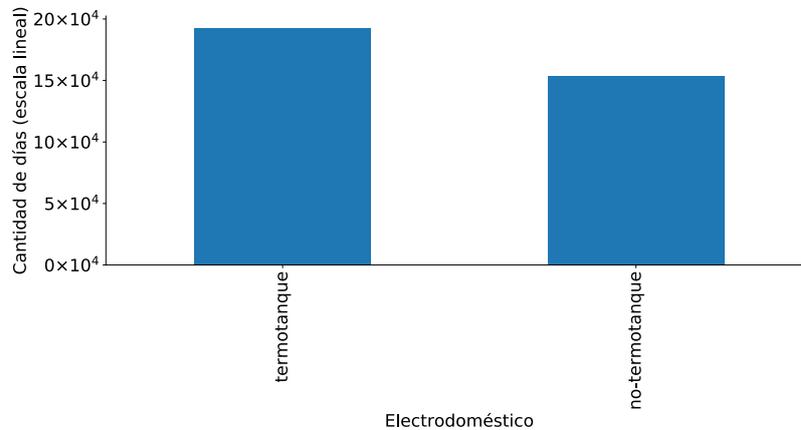


Figura 4.6: Gráfico de barras de la cantidad de “termotanque” y “no-termotanque”.

Figura 4.5 se presenta en escala \log_{10} . Por esta razón, resulta de particular interés evaluar los algoritmos como un clasificador binario para identificar si una serie temporal pertenece a un termotanque o no. La Figura 4.6 muestra la cantidad de datos correspondientes al problema binario, evidenciando que, mediante la integración de diversas bases de datos, se consiguió equilibrar las clases.

4.2.2. Algoritmos de clasificación

En esta sección se describen los algoritmos implementados para la tarea de clasificación de electrodomésticos siguiendo el esquema de la Figura 4.1. Se detallarán tanto los algoritmos de clasificación multiclase, que permiten la categorización de los electrodomésticos según su tipo específico, como los algoritmos de clasificación binaria, que se derivan de los modelos multiclase.

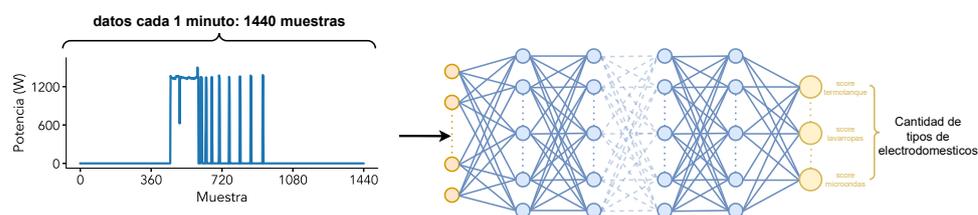
4.2.2.1. Algoritmos Multiclase

En este trabajo se escogieron a las redes neuronales profundas como el algoritmo a utilizar para la clasificación multiclase. Resultan adecuadas debido a su capacidad de adaptarse fácilmente a este tipo de tareas, permitiendo añadir una última capa con un número de neuronas igual a la cantidad de clases, cuyo valor de salida representará un puntaje (o probabilidad) de pertenencia a dicha clase.

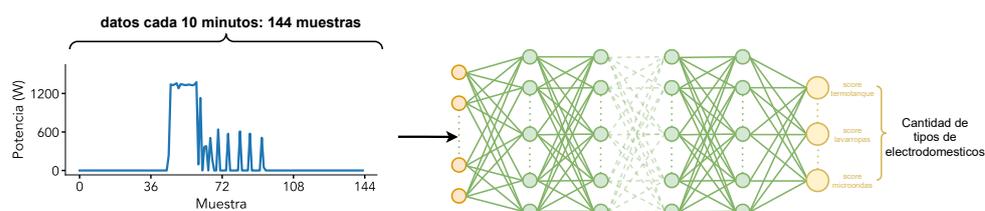
Las redes neuronales son implementadas a varias frecuencias, desde una muestra por minuto, hasta una muestra al día. Dado que se utiliza una ventana diaria, los tamaños de entrada varían desde 1440 hasta una única muestra obteniéndose varias configuraciones. Esto significa que para cada tasa de muestreo se entrena una red neuronal diferente. La Figura 4.7 ilustra esquemáticamente cada una de estas configuraciones de clasificación multiclase.

Capítulo 4. Identificación intrusiva del tipo de electrodoméstico

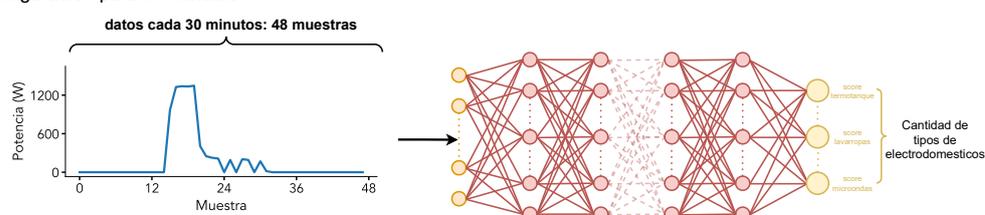
- Configuración para 1 minuto



- Configuración para 10 minutos



- Configuración para 30 minutos



- Configuración para 2 horas

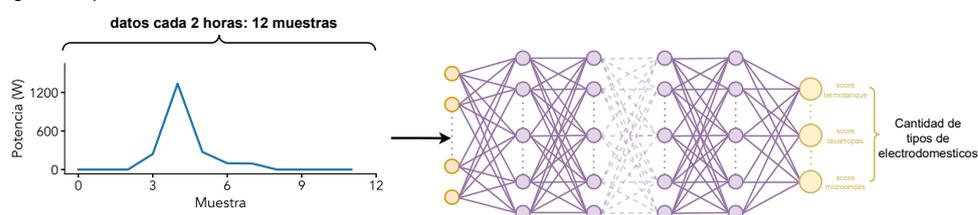


Figura 4.7: Configuraciones de clasificación de series temporales de electrodomésticos a distintas tasa de muestreo.

4.2.2.2. Arquitecturas de red neuronal

Se escogieron arquitecturas del estado del arte en el área de clasificación de series temporales en dominios genéricos. En concreto, las arquitecturas que se compararon en cada configuración fueron: **ResNet** [114], **InceptionTime**[115], **RNN**[116], **LSTM**[116], **MLP**[117], **XCM**[118] y **FCN**[117]. En el Apéndice A se incluye una descripción de cada una de estas arquitecturas.

4.2.2.3. Clasificación Binaria

Para la clasificación binaria “termotanque” o “no-termotanque”, se emplean las mismas arquitecturas de redes neuronales y configuraciones descritas para la

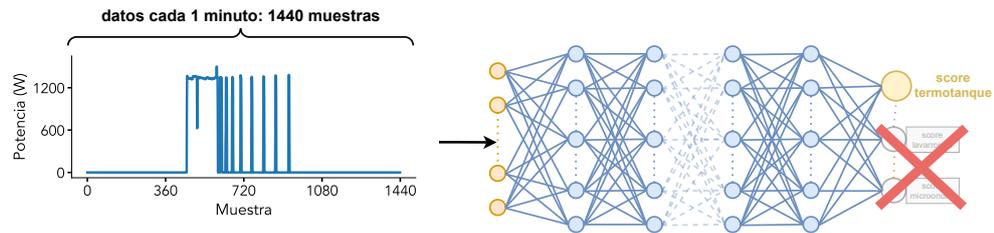


Figura 4.8: Configuraciones de clasificación binaria a partir de la configuración de clasificación multiclase.

clasificación multiclase. Sin perjuicio de lo anterior, en este caso se utiliza exclusivamente el puntaje de salida correspondiente a la neurona del termotanque, tal como se ilustra en la Figura 4.8.

Cabe destacar que no se vuelve a entrenar la red neuronal, sino que se emplea la misma red previamente entrenada para el caso multiclase. De esta forma, se obtiene un algoritmo que, al recibir una serie temporal de un electrodoméstico, devuelve un único valor, lo cual resulta adecuado para una clasificación binaria.

4.3. Métricas

El diseño y evaluación de los algoritmos propuestos requiere métricas de desempeño adecuadas al problema que se quiere resolver. En este caso se propone el uso de las métricas clásicas de clasificación binaria y multiclase que se resumen a continuación.

4.3.1. Métricas de clasificación binarias

Las métricas de clasificación binaria utilizadas para evaluar el desempeño de los algoritmos incluyen las siguientes cantidades:

- Verdadero positivo (**TP**): se refiere a una predicción correcta del termotanque.
- Falso positivo (**FP**): se refiere a una predicción incorrecta del no-termotanque.
- Verdadero negativo (**TN**): se refiere a una predicción correcta del no-termotanque.
- Falso negativo (**FN**): se refiere a una predicción incorrecta del termotanque.

A partir de las que se derivan la siguientes métricas:

- **Accuracy**: mide qué porcentaje de predicciones fueron correctas. Se calcula como la suma de TP y TN dividida por el número total de predicciones.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}.$$

Capítulo 4. Identificación intrusiva del tipo de electrodoméstico

- **Precision:** mide la proporción de predicciones positivas que fueron correctas. Se calcula como el número de TP dividido por la suma de TP y FP.

$$Precision = \frac{TP}{TP + FP}.$$

- **Recall:** mide la proporción de casos positivos que fueron detectados correctamente. Se calcula como el número de TP dividido por la suma de TP y FN.

$$Recall = \frac{TP}{TP + FN}.$$

- **F1-Score:** es una métrica que combina la Precision y el Recall en un solo valor. Se calcula como el promedio armónico entre el Precision y el Recall.

$$F1 - Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}.$$

4.3.2. Métricas de clasificación multiclase

Para el caso multiclase, se utilizan métricas que generalizan las definiciones binarias existentes [119]. Las tres variantes más comunes son *micro*, *macro* y *weighted*.

- *micro*: Las métricas se calculan globalmente contando los verdaderos positivos, falsos positivos y falsos negativos totales en todas las clases. Esto implica que el rendimiento de cada una se pondera de igual manera.
- *macro*: Las métricas se calculan en cada clase individualmente y luego se promedian en todas ellas. Esto significa que cada clase se pondera de igual manera en la puntuación final. Este método es útil para evaluar el rendimiento del modelo en cada categoría individual, independientemente de la distribución de estas en el conjunto de datos.
- *weighted*: Las métricas se calculan para cada clase individualmente y luego se promedian en todas ellas, ponderadas por el número de muestras de cada una. Esto significa que cada clase se pondera según su representación en el conjunto de datos. Este método es útil para evaluar el rendimiento del modelo en cada clase individual, teniendo en cuenta la distribución de estas en el conjunto de datos.

En este trabajo, se emplea la variante *weighted*, ya que se busca obtener buenos rendimientos en la detección de termotanques, los cuales representan la clase mayoritaria. Por lo tanto, para el caso multiclase, las definiciones de las métricas para la clase k son las siguientes:

$$Precision_k = \frac{TP_k}{TP_k + FP_k},$$
$$Recall_k = \frac{TP_k}{TP_k + FN_k},$$

4.4. Procedimiento de entrenamiento

$$F1-Score_k = 2 \cdot \frac{Precision_k \cdot Recall_k}{Precision_k + Recall_k}.$$

Luego se promedian ponderadamente según la cantidad de muestras de posee cada clase:

$$Accuracy_{weighted} = \frac{1}{N} \sum_{k=1}^L TP_k,$$
$$Precision_{weighted} = \frac{1}{N} \sum_{k=1}^L N_k \cdot Precision_k,$$
$$Recall_{weighted} = \frac{1}{N} \sum_{k=1}^L N_k \cdot Recall_k,$$
$$F1-Score_{weighted} = \frac{1}{N} \sum_{k=1}^L N_k \cdot F1-Score_k.$$

Donde L es la cantidad de clases a clasificar, N la cantidad total de series temporales y N_k es la cantidad de series temporales de la clase k .

En lo que resta del capítulo al presentar resultados de clasificación multiclase, se sobreentiende que se utiliza la variante *weighted* aunque no se aclare explícitamente.

4.4. Procedimiento de entrenamiento

El procedimiento de entrenamiento consiste en:

1. Entrenar a tasa de 1 minuto cada una de las arquitecturas de red neuronal de clasificación multiclase.
2. Binarizar los clasificadores multiclase a tasa 1 minuto para transformarlos en binarios como se muestra en la Figura 4.8.
3. Entrenar a todas las tasas de muestreo la arquitectura que mejor funcione sobre tasas de 1 minuto.

4.5. Hiperpármetros

Los hiperparámetros utilizados para todas las redes neuronales son los que se presentan en la Tabla 4.1.

4.6. Resultados

En esta sección se presentan los resultados alcanzados para cada una de las métricas de evaluación en cada uno de los modelos entrenados. Primero se reportan los resultados de clasificación multiclase, seguido de los resultados de clasificación binaria, y finalmente los resultados al variar la frecuencia de muestreo.

Capítulo 4. Identificación intrusiva del tipo de electrodoméstico

Hiperparámetro	
Función de pérdida	Entropía cruzada
Tasa de aprendizaje (learning rate)	1×10^{-4}
Tamaño de lote (batch size)	128 muestras
Criterio de detención	Early stopping con paciencia de 4 épocas, monitorizando el F1-Score de validación
Optimizador	AdamW [120]

Tabla 4.1: Hiperparámetros utilizados en redes neuronales de clasificación.

4.6.1. Resultados de clasificación multiclase

La Tabla 4.2 presenta los resultados obtenidos por cada una de las arquitecturas en los conjuntos de entrenamiento y validación en el caso multiclase. Se destaca que la arquitectura ResNet logra el mejor desempeño en el conjunto de validación, alcanzando un F1-Score de 0,728, seguida muy de cerca por la arquitectura InceptionTime con 0,699. En cuanto a los modelos no convolucionales, no logran desempeños adecuados, alcanzando valores de F1-Score inferiores a 0,45, probablemente debido a que la estructura de su arquitectura no les facilitó el proceso de aprendizaje.

	Entrenamiento				Validación			
	Accuracy	Precision	Recall	F1-score	Accuracy	Precision	Recall	F1-score
FCN	0.610	0.639	0.610	0.589	0.581	0.585	0.581	0.546
InceptionTime	0.790	0.800	0.790	0.775	0.726	0.705	0.726	0.699
LSTM	0.564	0.319	0.564	0.407	0.523	0.274	0.523	0.360
MLP	0.572	0.382	0.572	0.423	0.535	0.306	0.535	0.378
RNN	0.564	0.319	0.564	0.407	0.523	0.274	0.523	0.360
ResNet	0.825	0.825	0.825	0.813	0.747	0.730	0.747	0.728
XCM	0.420	0.491	0.420	0.437	0.425	0.467	0.425	0.433

Tabla 4.2: Resultados de clasificación multiclase sobre el conjunto de entrenamiento y validación.

Los resultados sobre el conjunto de test se presentan sobre la arquitectura ResNet, en virtud de que es la que obtiene los mejores resultados en validación. En la Tabla 4.3 se pueden apreciar las métricas obtenidas en los conjuntos de entrenamiento, validación y test. Se observa que para los tres conjuntos son similares, siendo incluso superior en test que en validación, lo que sugiere que no hay sobreajuste en el proceso de entrenamiento. Este resultado es un indicador de que el modelo está generalizando adecuadamente y no está aprendiendo patrones específicos del conjunto de entrenamiento que no se apliquen a otros conjuntos.

La Figura 4.9 muestra la matriz de confusión multiclase obtenida en el conjunto de test con el modelo ResNet. En esta figura, se puede apreciar que los electrodomésticos como el termotanque y la heladera con freezer, tienen un excelente desempeño con valores de 0,96 y 0,97 en Accuracy, respectivamente. Por otro lado, se observa que un electrodoméstico de bajo consumo, como las lámparas, presentan un desempeño pobre.

	Entrenamiento	Validación	Test
Accuracy	0.825	0.747	0.775
Precision	0.825	0.730	0.785
Recall	0.825	0.747	0.775
F1-score	0.813	0.728	0.767

Tabla 4.3: Resultados de clasificación multiclase para el mejor modelo, ResNet.

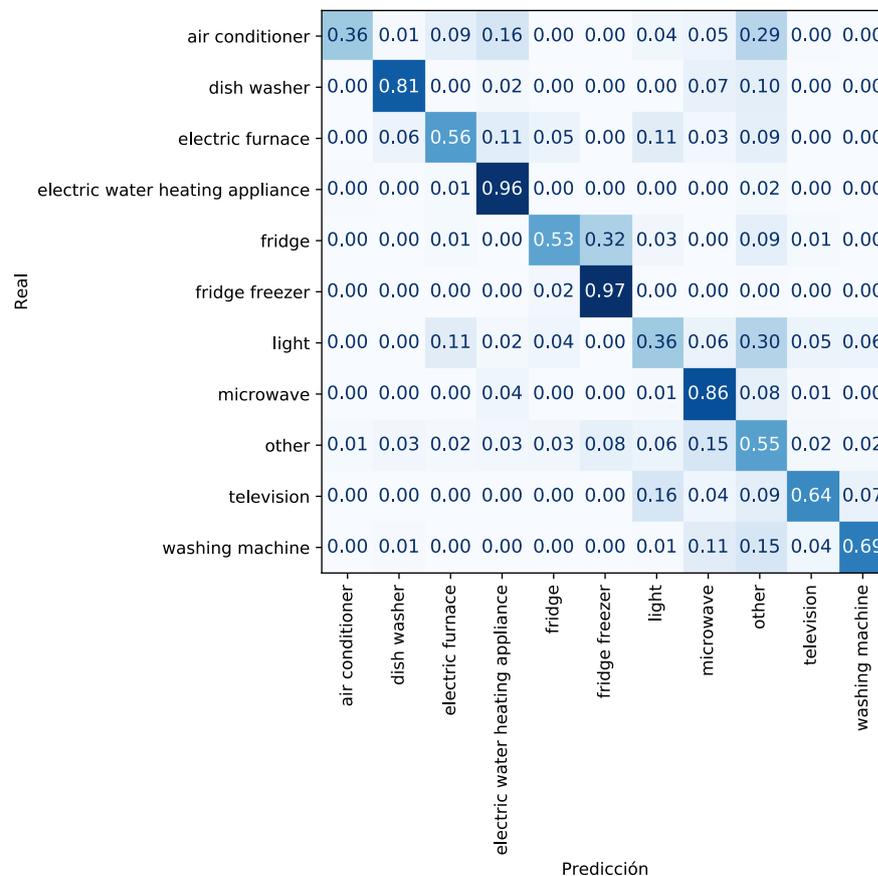


Figura 4.9: Matriz de confusión sobre el conjunto de test normalizada a lo largo de las filas utilizando el modelo ResNet. Se muestran los 10 electrodomésticos con mayor cantidad de datos, mientras que la categoría “other” agrupa a todos los demás.

En la Figura 4.10 se pueden ver ejemplos de clasificación de varios electrodomésticos del conjunto de test, en particular se aprecia el top 5 con mayor probabilidad asignada. Se observan tres casos de éxito, el *a*, *b* y *c*, mientras que una clasificación incorrecta, la *d*.

Capítulo 4. Identificación intrusiva del tipo de electrodoméstico

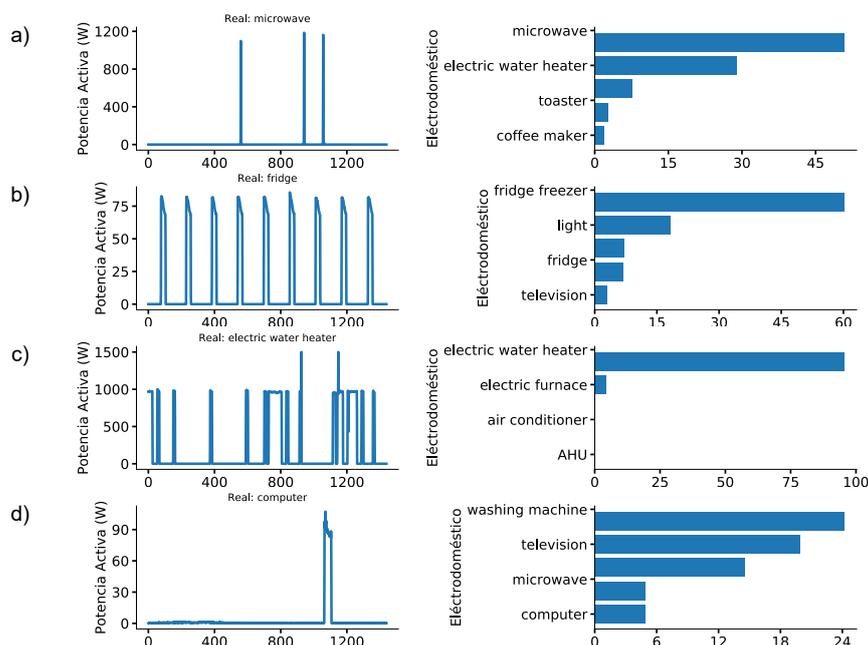


Figura 4.10: Probabilidades retornadas por el modelo ResNet al alimentarlo distintas series temporales del conjunto de test.

4.6.1.1. Análisis de la última capa

Una forma de interpretar los resultados de un modelo de aprendizaje profundo es analizando las características de alguna de sus capas intermedias. En este caso, se ha seleccionado la capa previa a la capa de salida de la red ResNet, la cual tiene una dimensión de 128.

Para visualizar las características de la penúltima capa en dos dimensiones, se reduce la dimensión a 2 utilizando el algoritmo t-SNE. En la Figura 4.11, se muestra la distribución de los puntos de los 10 electrodomésticos más comunes en el conjunto de test. Se observa que se forman agrupaciones de electrodomésticos en el espacio de características, que se corresponden con los resultados de la matriz de confusión presentada en la Figura 4.9.

Los electrodomésticos que son más difíciles de distinguir, como las lámparas, se encuentran dispersos en distintas regiones del espacio de características, mientras que electrodomésticos como el termotanque y el microondas forman agrupaciones más compactas y distinguibles. Además, se observa que los puntos correspondientes a aires acondicionados se superponen principalmente con los de termotanques. También, electrodomésticos similares, como la heladera y la heladera con freezer forman clusters entremezclados.

4.6.2. Resultados de clasificación binaria

En la Tabla 4.4 se presentan los resultados obtenidos para los conjuntos de entrenamiento y validación en la tarea de clasificación binaria, donde se utilizó la

4.6. Resultados

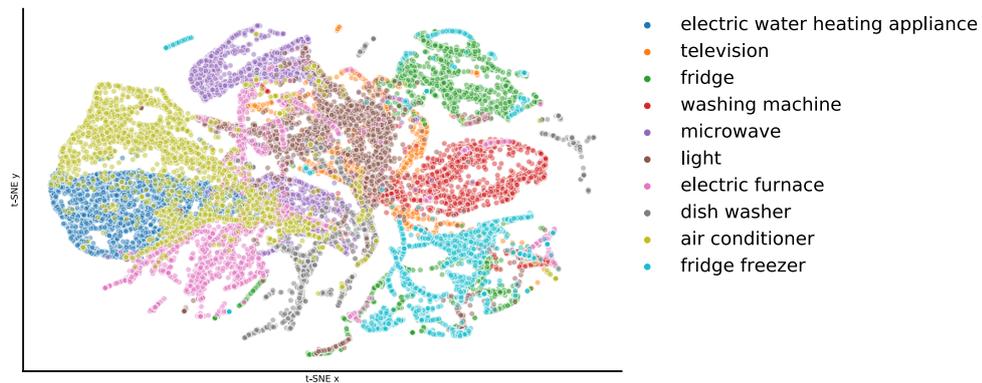


Figura 4.11: Características de la penúltima capa del modelo multiclase ResNet, aplicando reducción a dimensión 2 mediante t-SNE.

técnica de binarización de la salida de los clasificadores multiclase para obtener la clasificación de termotanque o no termotanque. Se puede observar que el modelo ResNet obtiene el mejor F1-Score sobre validación con un valor de 0,972, seguido de cerca por el modelo InceptionTime. Los modelos no convolucionales presentan valores de Accuracy cercanos a 0,5, lo que indica que no lograron aprender la tarea de manera efectiva, mientras que el modelo XCM, que presentó un pobre desempeño en la tarea de clasificación multiclase, muestra un desempeño aceptable en la tarea binaria.

	Entrenamiento				Validación			
	Accuracy	Precision	Recall	F1-score	Accuracy	Precision	Recall	F1-score
FCN	0.911	0.912	0.911	0.911	0.917	0.917	0.917	0.917
InceptionTime	0.965	0.965	0.965	0.965	0.967	0.968	0.967	0.967
LSTM	0.564	0.319	0.564	0.407	0.523	0.274	0.523	0.360
MLP	0.586	0.730	0.586	0.457	0.548	0.711	0.548	0.418
RNN	0.564	0.319	0.564	0.407	0.523	0.274	0.523	0.360
ResNet	0.969	0.969	0.969	0.969	0.972	0.972	0.972	0.972
XCM	0.749	0.770	0.749	0.750	0.801	0.809	0.801	0.800

Tabla 4.4: Resultados de clasificación binaria sobre el conjunto de entrenamiento y validación.

La Tabla 4.5 refleja los resultados obtenidos por el modelo ResNet en el conjunto de test, obteniendo 0,961 de F1-Score. Se puede observar que las métricas en el conjunto de test son similares a las obtenidas en los conjuntos de entrenamiento y validación, lo que sugiere que el modelo no presenta sobreajuste.

4.6.3. Resultados al variar la tasa de muestreo

Para evaluar la capacidad del modelo ResNet en distinguir “termotanque” y “no-termotanque” a partir de señales de energía de diferentes resoluciones temporales, se entrenaron un total de 36 modelos ResNet con señales a distintas tasas de muestreo, desde una muestra por minuto hasta una muestra por día.

Capítulo 4. Identificación intrusiva del tipo de electrodoméstico

	Entrenamiento	Validación	Test
Accuracy	0.969	0.972	0.961
Precision	0.969	0.972	0.961
Recall	0.969	0.972	0.961
F1-score	0.969	0.972	0.961

Tabla 4.5: Resultados de clasificación binaria para el mejor modelo, ResNet.

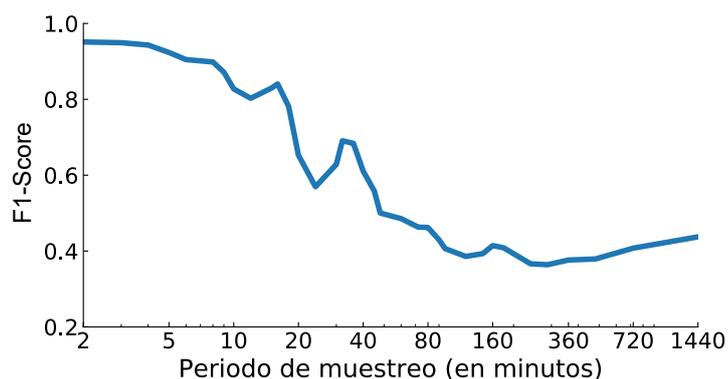


Figura 4.12: Evolución del F1-Score al incrementar la tasa de muestreo en el problema binario.

En la Figura 4.12 se muestra cómo evoluciona el F1-Score en función del período de muestreo utilizado. Se puede observar que a medida que aumenta el período de muestreo, el desempeño del clasificador se deteriora. En particular, para períodos de muestreo mayores a 20 minutos, se alcanza un F1-Score de entre 0,4 y 0,6, lo que indica que el clasificador es casi aleatorio en su capacidad de distinguir entre “termotanque” y “no-termotanque”. Esto sugiere que la información de energía registrada con pocas muestras no es suficiente para caracterizar adecuadamente el comportamiento de los electrodomésticos y así distinguir sus patrones de consumo.

Capítulo 5

Desagregación no intrusiva de electrodomésticos

En este capítulo se aborda la desagregación no intrusiva del consumo eléctrico en series temporales mediante un enfoque basado en redes neuronales. La propuesta se centra en analizar el desempeño sobre termotanques y vehículos eléctricos utilizando datos proporcionados por medidores inteligentes de UTE, los cuales registran el consumo cada 15 minutos.

5.1. Definición del problema

Se toma como referencia la formulación presentada en [121], la cual es de la siguiente manera:

$$P_{agg}(t) = f(P_1(t), \dots, P_M(t), e(t)) = \sum_{m=1}^M P_m(t) + e(t). \quad (5.1)$$

Aquí, $P_{agg}(t)$ representa la potencia agregada, $P_m(t)$ indica la potencia del electrodoméstico m , y $e(t)$ es un término de error que surge debido al ruido en la instalación eléctrica y a dispositivos desconocidos. La fórmula se expresa para el instante de tiempo t . Como se puede observar, la función f consiste en la suma de las potencias de todos los electrodomésticos.

El objetivo en NILM es encontrar $f^{-1}(P_{agg}(t))$, lo que representa determinar los valores de $P_m(t)$ a partir de $P_{agg}(t)$. En términos matemáticos:

$$P_1(t), \dots, P_M(t), e(t) = f^{-1}(P_{agg}(t)).$$

Sin embargo, este problema es NP-completo [122], lo que significa que encontrar soluciones exactas en tiempo polinomial es altamente improbable debido a la complejidad computacional asociada. Por lo tanto, en lugar de buscar soluciones exactas, es necesario implementar algoritmos aproximados.



Figura 5.1: Diagrama bloques para implementar algoritmos de NILM.

5.2. DL-NILM: Deep Learning para NILM

En esta sección se expresa una descripción detallada de los algoritmos utilizados en el proceso de desagregación de cargas. El flujo a implementar se muestra en el diagrama de bloques de la Figura 5.1.

5.2.1. Datos

5.2.1.1. Fuente de datos

La primera etapa consiste en la selección de datos, en la cual se escogieron las bases de datos UTEFING_TT y UTEFING_VE proporcionadas por UTE y presentadas en el Capítulo 3.6.7, que contienen series temporales de termotanques y vehículos eléctricos, respectivamente.

Para recordar, estas bases poseen los siguientes datos:

- UTEFING_TT: Potencia activa y reactiva agregada promedio cada 15 minutos. Potencia activa del termotanque promedio cada 1 minuto.
- UTEFING_VE: Potencia activa y reactiva agregada promedio cada 15 minutos. Potencia activa del vehículo eléctrico promedio cada 15 minutos.

En el Capítulo 3.7.5, se mencionó que a tasas de muestreo distintas, los electrodomésticos pueden modificar su patrón de consumo. En particular, se mencionó que electrodomésticos como el termotanque dejan de ser de tipo ON-OFF para pasar a ser un dispositivo de consumo variable. Para ilustrar esto, en la Figura 5.2 se presentan varios ejemplos de curvas de termotanques a tasas de 1 minuto y 15 minutos. Se puede observar que a una tasa de muestreo de 1 minuto el patrón de consumo es claramente ON-OFF, mientras que a una tasa de 15 minutos el patrón se convierte en un dispositivo de consumo variable.

En el caso de los vehículos eléctricos, no ocurre lo mismo. Incluso a una tasa de muestreo de 15 minutos, el patrón de consumo sigue siendo de tipo ON-OFF, tal como se observa en la Figura 5.3.

5.2.1.2. Separación de datos

La etapa de separación de datos se encarga de dividir las series temporales de varios meses de cada hogar en tramos más pequeños para servir como entrada y salida de los algoritmos. Como se vio en el Capítulo 4.2.1.2 del capítulo de

5.2. DL-NILM: Deep Learning para NILM

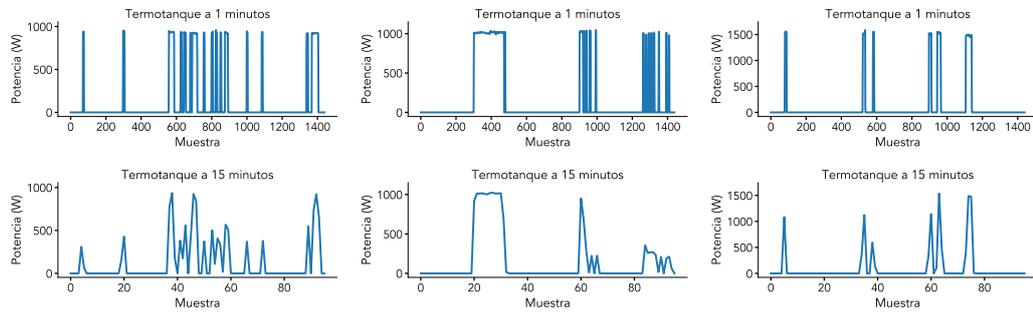


Figura 5.2: Series temporales de termotanques a tasa de 1 minuto y a tasa de 15 minutos. Cada columna corresponde a la misma curva de consumo a distinta tasa.

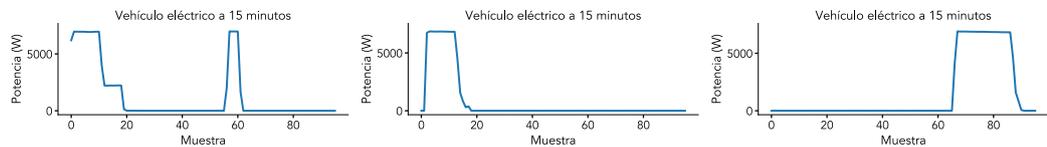


Figura 5.3: Series temporales de vehículo eléctrico a tasa de 15 minutos.

clasificación de electrodomésticos, en este trabajo **se separan los datos de forma diaria** de la forma que se muestra en la Figura 5.4.

Bajo los mismos argumentos que para ILM, esta división es una elección innovadora, ya que al tener los datos en ventanas diarias, las redes neuronales pueden adquirir contexto del patrón de consumo del usuario, lo que mejorará la desagregación. Es importante recordar que los algoritmos deben realizar dos tareas complementarias: aprender las curvas de consumo típicas de los electrodomésticos e identificar el patrón de consumo del usuario para cada uno de ellos.

5.2.1.3. Pre-procesamiento

Limpieza de datos: El pre-procesamiento consiste en eliminar aquellas series temporales que no contienen todas las mediciones realizadas a lo largo del día. Para llevar a cabo este pre-procesamiento, se identifican todas las series temporales que no contienen todas las mediciones comparando el número de mediciones realizadas en un día con 1440 (correspondiente a mediciones cada minuto) o 96 (correspondiente a mediciones cada 15 minutos). A través de este proceso, se descartan aproximadamente el 2,7% de los datos.

5.2.1.4. Conjunto de datos de entrenamiento, validación y test

Es fundamental elegir cuidadosamente como dividir el conjunto de datos en los conjuntos de entrenamiento, validación y prueba. Si no se realiza de manera adecuada, existe el riesgo de que los datos pertenecientes a un mismo electrodoméstico se encuentren en más de un conjunto al mismo tiempo.

Capítulo 5. Desagregación no intrusiva de electrodomésticos

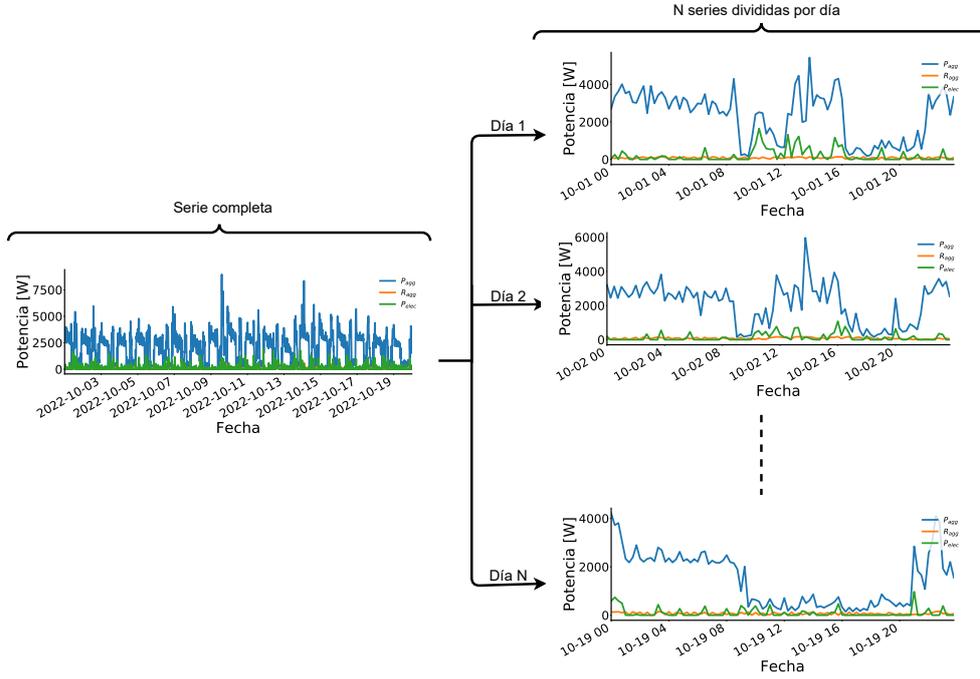


Figura 5.4: Esquema de separación diaria de datos para desagregación.

Es importante mencionar que este problema también se presentó al describir la tarea de clasificación en el Capítulo 4.2.1.4. La solución implementada es la misma, asignándose el 70 % de los hogares al conjunto de entrenamiento, 15 % al conjunto de validación y 15 % restante al conjunto de prueba. De esta forma, se asegura que los datos utilizados en cada uno de los conjuntos son independientes entre sí y no se sobreestima el rendimiento del modelo.

5.2.1.5. Normalización de los datos

Las series temporales de entrada y salida son normalizadas. Esta etapa de pre-procesamiento es esencial, ya que facilita el aprendizaje del modelo.

La normalización de los datos de entrada implica ajustar la potencia activa y reactiva agregada de acuerdo con los valores de media y varianza correspondientes a cada una de ellas en el conjunto de entrenamiento. Para llevar adelante este proceso, se aplicaron las fórmulas siguientes:

$$P_{agg_norm} = \frac{P_{agg} - \mu_{\text{train}}(P_{agg})}{\sigma_{\text{train}}(P_{agg})},$$

$$R_{agg_norm} = \frac{R_{agg} - \mu_{\text{train}}(R_{agg})}{\sigma_{\text{train}}(R_{agg})}.$$

La normalización de los datos de salida de la red se centra únicamente en ajustar la potencia activa desagregada de consumo del electrodoméstico de acuerdo con los valores de media y varianza de todas las series pertenecientes al conjunto

5.2. DL-NILM: Deep Learning para NILM

de entrenamiento. Para procesar este ajuste, se empleó una fórmula similar a las mencionadas previamente:

$$P_{elec.norm} = \frac{P_{elec} - \mu_{train}(P_{elec})}{\sigma_{train}(P_{elec})}.$$

La normalización de los datos de entrada y salida en general permite que el modelo aprendan de manera más eficiente, habida cuenta de que los distintos canales de entrada y salida están en un rango similar.

Con el fin de prevenir la filtración de información proveniente de los conjuntos de validación y test, la normalización de todos los conjuntos se realiza empleando la media y varianza obtenidas del conjunto de entrenamiento.

5.2.1.6. Aumento de datos

En la etapa de pre-procesamiento se aplicaron diversas técnicas de *data augmentation* similares a las utilizadas en la clasificación de electrodomésticos, tal como se mencionó en el Capítulo 4.2.1.6. Dichas técnicas permiten generar variaciones de los datos existentes, ayudando a prevenir el sobreajuste y mejorar la generalización del modelo.

Inicialmente, se multiplicó cada serie temporal por un número aleatorio cercano a 1, lo que introdujo ligeras variaciones en las escalas de potencia de las series.

A continuación, se añadió ruido gaussiano a los datos. Esto se llevó a cabo generando una serie temporal en la que cada punto sigue una distribución normal, para luego sumar dicho ruido a la serie temporal de potencia.

Posteriormente, se aplicó una rotación circular para variar ligeramente la hora de las series temporales. Dicho ajuste consistió en desplazar los puntos de la serie temporal en un pequeño número aleatorio de posiciones, seguido de la actualización del índice de tiempo con el fin de mantener la coherencia.

Finalmente, se empleó la técnica RandomCrop para fijar la potencia a $0W$ en un segmento contiguo aleatorio de la serie. Esto se logró seleccionando aleatoriamente un punto de inicio y un punto final dentro de la serie temporal y asignando la potencia a $0W$ en ese rango.

En conjunto, estas técnicas de *data augmentation* permiten generar una gran cantidad de variantes a partir de datos existentes, lo que contribuye a mejorar el rendimiento del modelo de desagregación.

Vale mencionar que estas técnicas se implementaron utilizando la biblioteca ya mencionada anteriormente disponible en https://github.com/camilomarino/transforms1d_torch. A continuación, se presenta el código correspondiente a la implementación de estas técnicas de *data augmentation*:

```
from transforms1d_torch import transforms1d
transforms1d.Compose(
    [
        transforms1d.Multiply(min_value=0.75, max_value=1.25),
        transforms1d.GaussianNoise(mean=0.0, std=0.05),
        transforms1d.CircularShift1d(min_shift=0, max_shift=12),
```

```
transforms1d.RandomCrop(crop_percentage=0.1)  
]  
)
```

Esta etapa se realiza en tiempo real, por lo que no se pre-calculan las nuevas series temporales cada vez, sino que se calculan en el momento en que se toma un dato para entrenar se le aplica la cadena de operaciones.

5.2.2. Propuestas de modelos para calcular f^{-1}

El abordaje propuesto en la tesis es en la categoría de *no-event-based* y en particular la implementación de algoritmos de **redes neuronales profundas (DL)**. Se utiliza la variante *seq2seq*, Figura 2.3 del Capítulo 2, sobre series de potencia en tramos de un día. Además, se optó por la implementación de **un modelo por electrodoméstico**, en el entendido que las bases de datos escogidas solo cuentan con datos desagregados de termotanques y autos eléctricos.

La Ecuación (5.1) modela el problema solamente para la potencia activa. Sin perjuicio de lo anterior, y dado que se poseen datos de potencia reactiva agregada y en un contexto donde las redes neuronales son lo suficientemente flexibles para modelar funciones cualesquiera, y que cuanto más información se tenga es factible obtener mejores resultados, se decide incluir la potencia reactiva agregada como entrada a las redes neuronales. Para incorporar estos datos de potencia reactiva agregada, se utiliza un **modelo con dos canales de entrada** donde se tiene un canal de entrada para la potencia activa y otro canal de entrada para la potencia reactiva agregada. De esa forma, se puede aprovechar la información adicional que se posee y obtener un modelo más completo y preciso para la desagregación de electrodomésticos.

Dado que se tienen datos agregados de potencia activa y reactiva cada 15 minutos y que se trabaja con una ventana diaria, todas las arquitecturas de redes neuronales mencionadas tendrán como entrada a la red dos canales de tamaño **96**. Simultáneamente, la salida de la red será la serie de potencia activa del electrodoméstico en cuestión, termotanque o vehículo eléctrico. En el caso de los vehículos eléctricos se tienen datos cada 15 minutos, por lo que la salida de la red deberá tener esta tasa. En cambio, para los termotanques se poseen datos cada 1 minuto, siendo posible entrenar tanto modelos con salidas cada 15 minutos y cada 1 minuto. Por lo tanto, los tamaños de **salida** serán **96** y **1440** para 15 minutos y 1 minuto respectivamente.

Con lo dicho anteriormente, se tienen tres configuraciones distintas que modelan f^{-1} , dos para termotanques y una para vehículos eléctricos. La Figura 5.5 ilustra cada una de ellas.

Como se observa en la configuración *c.* de la Figura 5.5, la salida del modelo es de mayor tamaño que su entrada. Esto significa que los modelos, además de llevar a cabo la tarea de desagregación, deben realizar un sobre-muestreo de la señal (también conocido como súper-resolución de la señal). Esta situación añade una dificultad extra, ya que se deben cumplir dos tareas de manera simultánea. La razón para utilizar esta configuración radica en el interés de evaluar el desempeño

5.2. DL-NILM: Deep Learning para NILM

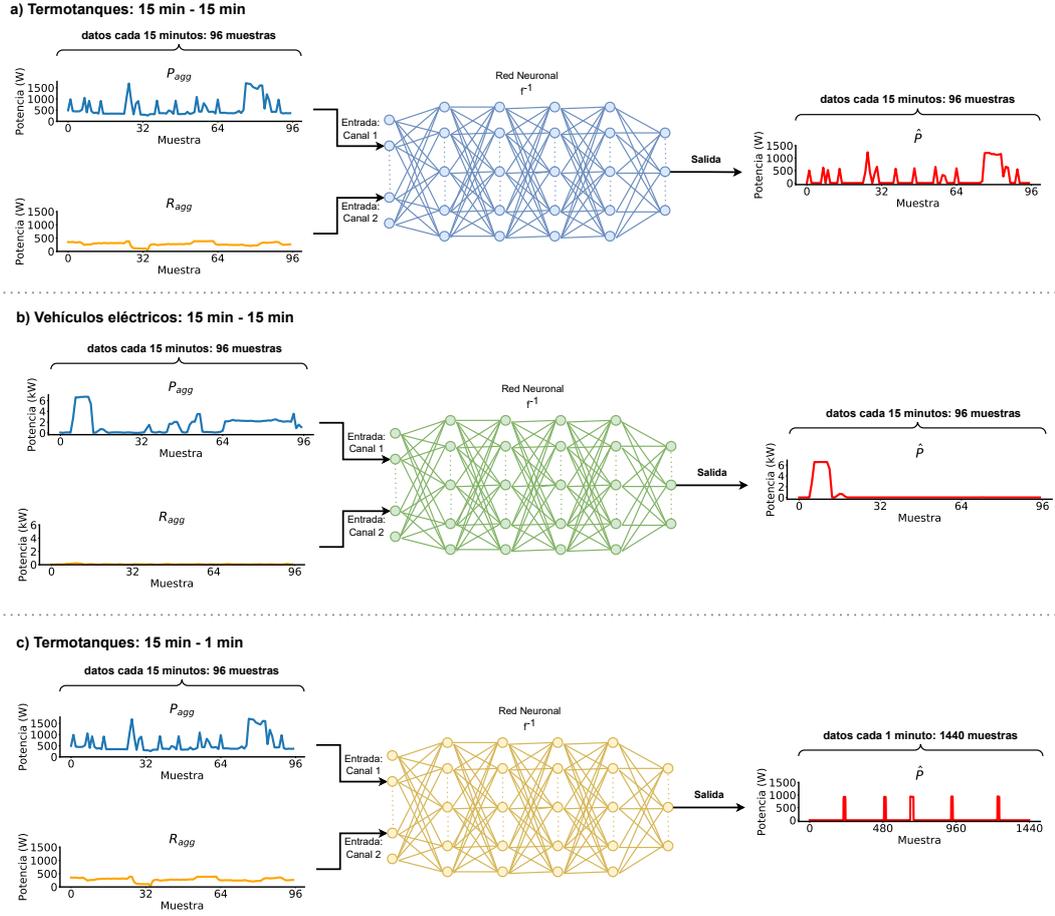


Figura 5.5: Configuraciones para computar f^{-1} con distintos tamaños de entrada y salida.

al utilizar la totalidad de los datos disponibles en comparación con la configuración que no emplea súper-resolución.

5.2.2.1. Arquitecturas de red neuronal

En cada configuración se utilizaron varias arquitecturas de red neuronal, variando la última capa para adaptarse al tamaño de salida correspondiente. Como fuente, se escogieron arquitecturas clásicas en el dominio de NILM utilizadas en varios artículos académicos. En concreto, las arquitecturas que se compararon en cada configuración fueron: **Denoising Autoencoder (DAE)** [42], **Fully Convolutional Denoising Autoencoder (FC-DAE)**, **BiLSTM** [42], **Seq2Seq** [56], **ResNet** [114], **InceptionTime**[115] y **Mean**. En el Apéndice A se da una descripción detallada de cada una de las arquitecturas.

De esta forma, se tienen tres configuraciones y para cada una de ellas ocho arquitecturas de red neuronal distintas. Los objetivos son evaluar todas las combinaciones para computar f^{-1} , obtener los resultados y analizarlos.

Capítulo 5. Desagregación no intrusiva de electrodomésticos

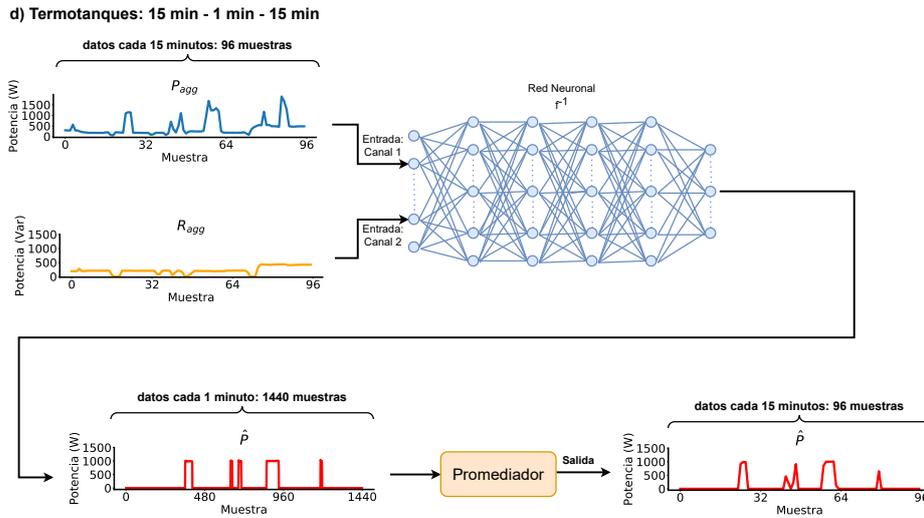


Figura 5.6: Esquema de la modificación introducida a la configuración c) en la que se agrega una etapa de post-procesamiento.

5.2.2.2. Enfoque alternativo: Optimización con restricciones

Si bien este documento se enfocó principalmente en algoritmos DL, también investigó un enfoque alternativo para el cálculo de f^{-1} . En tal sentido, se examinó un método *no basado en eventos* que aborda el problema como un caso de optimización con restricciones, conocido como NMF. En el Apéndice C se describen detalladamente NMF y sus variantes más populares. Asimismo, se presentan y analizan los resultados obtenidos al aplicar esta técnica sobre la base de datos AMPDs.

5.2.3. Post-procesamiento

Se plantea llevar a cabo un post-procesamiento en la configuración c) de la Figura 5.5. La idea consiste en utilizar la señal predicha a una tasa de 1 minuto y procesarla para llevarla a un intervalo de 15 minutos. La motivación detrás de este enfoque es que las arquitecturas utilizadas para desagregar a un lapso de 15 minutos solo aprovechan datos a esa misma tasa, sin emplear toda la información disponible a una tasa superior.

Para implementar esta estrategia de post-procesamiento, se toma la arquitectura de la red neuronal entrenada a una tasa de 1 minuto y se le añade una última capa que remuestra la señal a una tasa de 15 minutos. La Figura 5.6 muestra esta nueva configuración.

Este enfoque permite comparar los modelos generados a diferentes tasas, adaptando uno de ellos a la tasa del otro y evaluando su desempeño de manera consistente. Además, busca aprovechar al máximo todos los datos disponibles, utilizando toda la información para la generación del modelo.

5.3. Función de pérdida

Dado que se pretende resolver un problema de regresión instante a instante en una serie temporal, se penaliza el error cuadrático medio. Es decir:

$$\text{loss} = \frac{1}{N} \sum_{t=0}^{N-1} (f^{-1}(P_{agg}(t), R_{agg}(t)) - P_{elec}(t))^2.$$

En el Apéndice B, se proponen enfoques alternativos relacionados con la función de pérdida utilizada. Uno de ellos incluye un término que incorpora al clasificador de electrodomésticos. El otro enfoque consiste en ponderar de manera diferente el MSE, dependiendo de si el electrodoméstico a desagregar está encendido o no. Los experimentos realizados no arrojaron resultados concluyentes por lo que no se incluyen en este trabajo.

5.4. Métricas

En esta sección se presentan y comparan las métricas, cuya categorización más común es la presentada en [123], dividiéndose las mismas en: métricas de estado binario y métricas de regresión.

5.4.1. Métricas de estado binario

Como se mencionó en el Capítulo 3.7, los electrodomésticos poseen varios patrones de funcionamiento distintos. Sin embargo, las métricas de estado binario tratan a los electrodomésticos como si estos fueran de tipo ON-OFF. En base a este supuesto, se evalúa qué tan buena es la predicción del estado instante a instante.

En consecuencia, el objetivo de estas métricas será binarizar la señal real y la señal predicha, para así tratar al problema como uno de clasificación binaria. En la Figura 5.7 se ve un ejemplo de binarización de las señales.

Habida cuenta de lo anterior, las métricas de estado binario deben utilizarse con precaución en electrodomésticos que no son ON-OFF, ya que antes de evaluar los resultados las señales pasan por un proceso de binarización. En particular, vale recordar que los termotanques a un período de muestreo de 15 minutos no son de tipo ON-OFF.

5.4.1.1. Umbral de binarización ON-OFF (*threshold*)

La selección del umbral de binarización ON-OFF en el contexto de NILM presenta características diferentes a otros problemas de clasificación. Para este contexto, es necesario definir dos umbrales de potencia: uno para determinar cómo binarizar la serie real (o *target*) y otro para determinar cómo binarizar la serie predicha.

Para el umbral de la señal real, se elige un valor en potencia pequeño que garantice que el electrodoméstico está encendido. Este valor se fija en 100W.

Capítulo 5. Desagregación no intrusiva de electrodomésticos

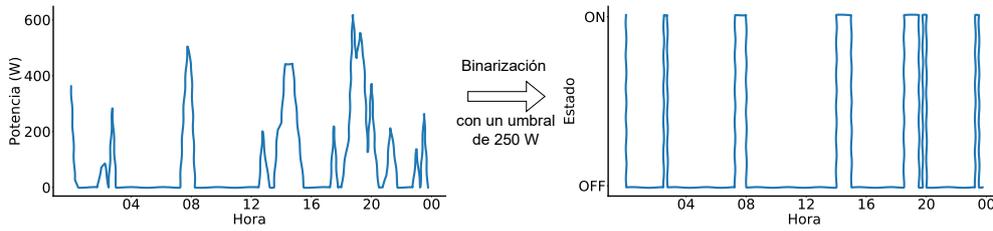


Figura 5.7: Ejemplo de binarización de una curva de potencia de un termotanque adquirido cada 15 minutos con un umbral de 250W.

Por otro lado, el umbral en potencia de la predicción es variable y se ajusta para optimizar la métrica objetivo seleccionada, como es común en problemas de clasificación.

5.4.1.2. Definición de las métricas

A continuación, se definen métricas usuales de clasificación binaria:

- Verdadero positivo (**TP**): se refiere a una predicción correcta del estado ON.
- Falso positivo (**FP**): se refiere a una predicción incorrecta del estado OFF.
- Verdadero negativo (**TN**): se refiere a una predicción correcta del estado OFF.
- Falso negativo (**FN**): se refiere a una predicción incorrecta del estado ON.

A partir de estas cuatro métricas, se calculan varias métricas adicionales:

- **Accuracy**: mide qué porcentaje de predicciones fueron correctas. Se calcula como la suma de TP y TN dividida por el número total de predicciones.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}.$$

- **Precision**: mide la proporción de predicciones positivas que fueron correctas. Se calcula como el número de TP dividido por la suma de TP y FP.

$$Precision = \frac{TP}{TP + FP}.$$

- **Recall**: mide la proporción de casos positivos que fueron detectados correctamente. Se calcula como el número de TP dividido por la suma de TP y FN.

$$Recall = \frac{TP}{TP + FN}.$$

- **F1-Score**: es una métrica que combina la Precision y el Recall en un solo valor. Se calcula como el promedio armónico entre el Precision y el Recall.

$$F1 - Score = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}.$$

5.5. Entrenamiento e Hiperparámetros

Las métricas anteriores están dadas para un umbral fijo, sin embargo, existen otras métricas que son útiles para medir el rendimiento general para un modelo de clasificación binaria, como la curva ROC y la AUC.

La curva ROC es una herramienta gráfica que se utiliza para visualizar la eficacia de un modelo de clasificación binaria. Se trata de un gráfico que muestra la tasa de verdaderos positivos en función de la tasa de falsos positivos para diferentes umbrales de clasificación. La curva ROC permite comparar diferentes modelos de clasificación y elegir el mejor en función de las necesidades específicas del problema.

La AUC (Área bajo la curva) es una medida numérica que se utiliza para evaluar la calidad de una curva ROC. Se calcula como el área bajo la curva ROC y su valor oscila entre 0 y 1. Una AUC de 1 indica un modelo perfecto, mientras que una AUC de 0.5 indica un modelo no mejor que el azar. Por lo tanto, cuanto mayor sea la AUC, mejor será el modelo de clasificación.

5.4.2. Métricas de regresión

Las métricas de regresión evalúan la precisión de la predicción de la potencia consumida por cada aparato en cada momento. Las mismas tienen en consideración electrodomésticos multiestado.

Por consiguiente, la evaluación se realiza sobre la base de las siguientes métricas:

- Error medio absoluto (MAE): Se calcula como el promedio del error absoluto entre la predicción y el valor real para cada electrodoméstico.

$$MAE = \frac{1}{N} \sum_t |P(\hat{t}) - P(t)|.$$

Siendo $P(\hat{t})$ y $P(t)$ la señal predicha y la señal real en el instante t respectivamente. Notar que esta métrica coincide exactamente con la función de pérdida utilizada.

- Error cuadrático medio (MSE): Se calcula como el promedio del error cuadrático entre la predicción y el valor real para cada aparato y para cada momento.

$$MSE = \frac{1}{N} \sum_t (P(\hat{t}) - P(t))^2.$$

- Raíz del error cuadrático medio (RMSE): Es la raíz cuadrada del MSE y tiene las mismas unidades que la señal, con lo cual es más interpretable.

$$RMSE = \sqrt{MSE}.$$

5.5. Entrenamiento e Hiperparámetros

En esta sección, se describen las decisiones tomadas y los distintos hiperparámetros utilizados en el entrenamiento de las arquitecturas de redes neuronales propuestas en el Apéndice A.2.

Capítulo 5. Desagregación no intrusiva de electrodomésticos

Se emplearon los optimizadores *Adam* [124] y su variante *AdamW* [120] en el proceso de entrenamiento. La elección de ambos se basa en que se han convertido en el estándar para optimizar arquitecturas de redes neuronales recientes.

La tasa de aprendizaje o *learning rate* (*lr*) se ajustó logarítmicamente desde 1×10^{-7} hasta 1×10^{-1} . Además, se incluye un *lr* adicional, como el descrito en [125]. El mismo consiste en realizar una búsqueda inicial del mejor *lr* bajo un criterio establecido en el artículo. No se utiliza ningún *scheduler* para modificar el *lr* a lo largo del entrenamiento.

El tamaño de lote o *batch size* se varió en potencias de 2 en un rango de 32 a 512, siendo este último el mayor valor para el cual era capaz de procesar la memoria *RAM* de la *GPU* de entrenamiento.

El entrenamiento de las redes finaliza mediante el criterio de *early stopping* con una paciencia de 8 épocas. La métrica que se sigue es la *loss* sobre el conjunto de validación. El modelo final es aquel cuya *loss* sobre validación tiene el menor valor.

En cuanto al método para buscar los mejores hiperparámetros, que son *lr*, *batch size* y optimizador, se realizó una búsqueda exhaustiva sobre todas las combinaciones posibles. El modelo escogido fue aquel con menor MAE sobre el conjunto de validación.

5.6. Resultados

En este punto se presentan los resultados de las métricas descritas. En todos los casos se reportan los resultados sobre los conjuntos de entrenamiento y validación para todos los modelos. Para el modelo con mejor resultado de MAE sobre el conjunto de validación, se reportan los resultados sobre el conjunto de test.

Se muestran los resultados para termotanques y vehículos eléctricos a tasa de 15 minutos. También se presentan los resultados para termotanques a tasa de 1 minuto. Notar que estas tasas se refieren a la tasa de la señal de salida del modelo, ya que la entrada es fija a tasa de 15 minutos.

5.6.1. Resultados sobre termotanques a tasa de 15 minutos

En la Tabla 5.1 se muestran los resultados de desagregación a tasa de 15 minutos sobre los termotanques para cada una de las arquitecturas de redes neuronales implementadas. Se presentan los resultados tanto para el conjunto de entrenamiento como de validación.

Además, se observan valores de precision en torno al 75 %, mientras que de recall es del orden del 85 %, obteniéndose una mayor existencia de falsos positivos que de falsos negativos. En otras palabras, las arquitecturas tienden a estimar consumos por arriba del umbral cuando en realidad no está ocurriendo ello, es decir, existe una tendencia a indicar que el electrodoméstico está encendido cuando en realidad no lo está. Por otro lado, el recall más elevado representa que gran parte de las veces que el termotanque realmente está por encima del umbral este es correctamente detectado por el algoritmo.

	Entrenamiento						Mejor Umbral
	MAE	RMSE	Accuracy	Precision	Recall	F1-Score	
DAE	121.8	216.6	86.4	67.5	59.5	63.2	-
FC-DAE	86.4	193.4	90.6	74.0	80.7	77.2	-
BiLSTM	67.9	166.6	92.7	79.2	85.3	82.2	-
Seq2Seq	96.0	183.4	90.1	73.6	77.5	75.5	-
ResNet	76.7	174.7	92.3	77.9	84.6	81.1	-
InceptionTime	76.5	175.4	92.1	77.7	83.9	80.7	-
Mean	217.9	345.7	-	-	-	-	-
	Validación						Mejor Umbral
	MAE	RMSE	Accuracy	Precision	Recall	F1-Score	
DAE	129.6	236.1	87.1	66.7	63.3	65.0	160
FC-DAE	92.4	207.1	90.6	71.1	84.8	77.3	140
BiLSTM	76.7	188.7	92.1	76.3	84.3	80.1	130
Seq2Seq	105.9	207.5	90.1	71.4	79.6	75.3	160
ResNet	84.3	193.3	91.9	75.2	85.8	80.1	140
InceptionTime	82.7	193.1	91.9	75.8	84.2	79.8	130
Mean	226.3	360.3	-	-	-	-	-

Tabla 5.1: Resultados de desagregación a tasa de 15 minutos sobre termotanques.

Los umbrales óptimos obtenidos en todos los casos mediante el criterio del mejor F1-score son del mismo orden en todos los modelos, en torno a 150W.

Se observan valores levemente inferiores de MAE en el conjunto de entrenamiento respecto al de validación, lo cual no sugiere sobreentrenamiento. En resumen, la arquitectura que presenta mejores resultados en validación en todas las métricas menos en recall es BiLSTM.

Una forma más ilustrativa de entender los resultados es analizar algunas series temporales de consumo agregado y la serie real del termotanque, junto con la predicción de los algoritmos. En tal sentido la Figura 5.8 muestra los resultados para cada una de las arquitecturas sobre el conjunto de validación, apreciándose que las predicciones en tres de los cuatro ejemplos son visualmente correctas. Sin perjuicio de lo anterior, el caso que presenta mayor dificultad es el correspondiente a la tercer columna, en donde a varios de los modelos le es difícil reproducir la forma de consumo del termotanque, probablemente debido al consumo elevado del usuario en ese día.

Siguiendo el criterio de escoger la arquitectura con mejor desempeño en MAE en validación, la arquitectura BiLSTM es la elegida. Con fines de analizar más a fondo este modelo, en la Figura 5.9 se aprecia la curva ROC, indicando el punto de umbral óptimo, en tanto la AUC es de 0,95. Esto evidencia un desempeño más que aceptable para distintos umbrales, pudiendo modificar el punto de funcionamiento según las necesidades de tener más o menos verdaderos positivos o falsos positivos.

También sobre el modelo BiLSTM se procedió a evaluar el desempeño del mismo sobre el conjunto de test, en la Tabla 5.2 se tienen los resultados numéricos sobre el conjunto de test para la mejor arquitectura. Si bien se observa una caída de rendimiento en todas las métricas del conjunto de test respecto a validación y

Capítulo 5. Desagregación no intrusiva de electrodomésticos

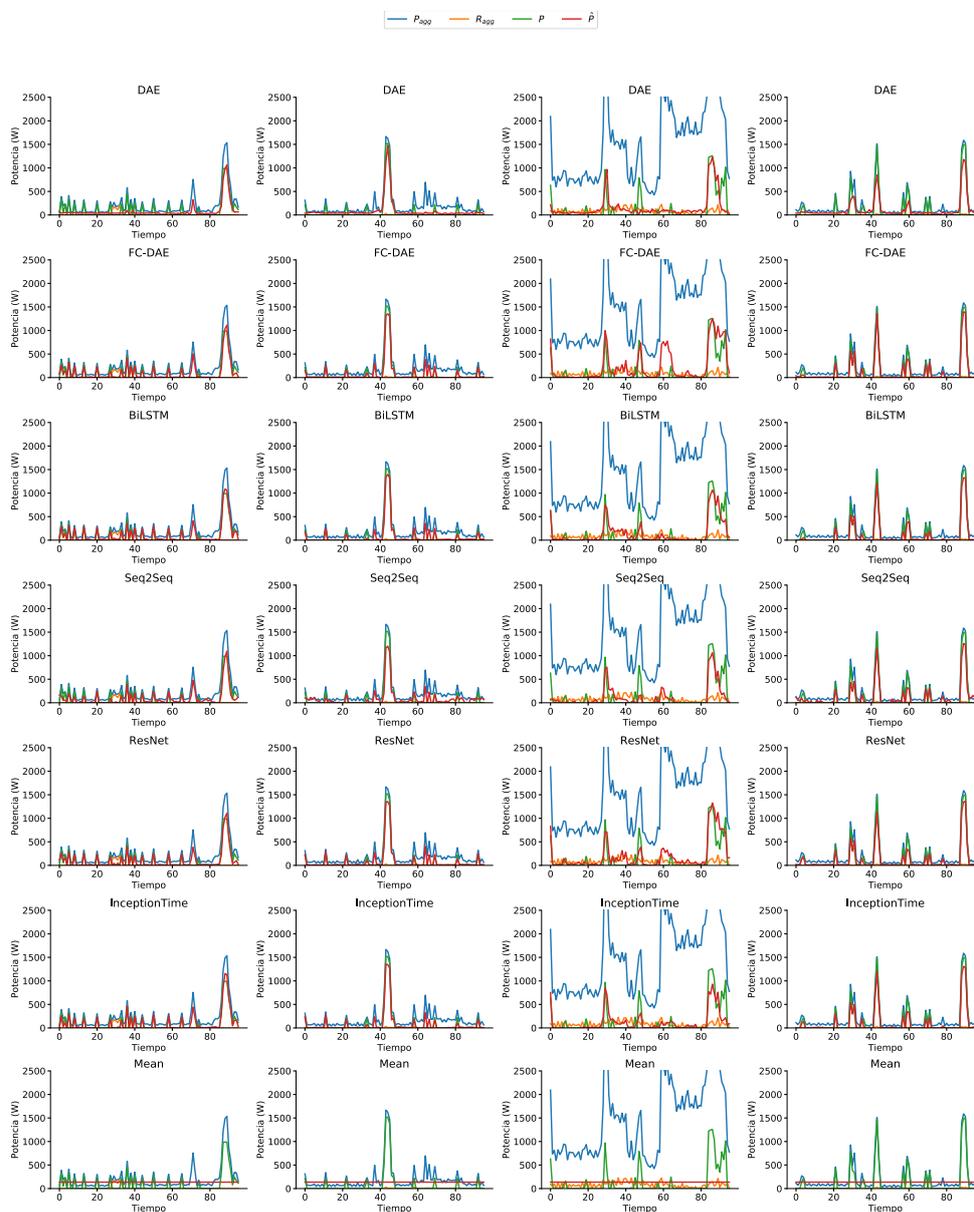


Figura 5.8: Ejemplos de resultados de desagregación de termotanques para todos los modelos a tasa de 15 minutos sobre el conjunto de validación. En cada fila se tienen resultados para el mismo modelo, en cada columna se tiene las mismas señales para comparar los resultados.

5.6. Resultados

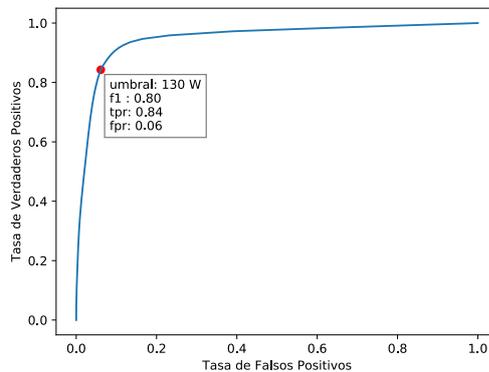


Figura 5.9: Curva ROC para la desagregación a tasa de 15 minutos sobre termotanques en el modelo BiLSTM. En rojo el punto de funcionamiento óptimo que maximiza el puntaje F1.

	Entrenamiento	Validación	Test
MAE	67.9	76.7	84.5
RMSE	166.6	188.7	203.3
Accuracy	92.7	92.1	90.6
Precision	79.2	76.3	74.5
Recall	85.3	84.3	83.9
F1-Score	82.2	80.1	78.9

Tabla 5.2: Resultados de desagregación 15 minutal sobre termotanques.

entrenamiento, dicha disminución no es significativa, lo que muestra que no existe sobre-ajuste.

También, en la Figura 5.10 se visualizan ejemplos para este mejor modelo sobre el conjunto de test. Se aprecia que se degrada un poco el desempeño respecto a los resultados de validación. En particular ocurre en algunos casos que el modelo no detecta la presencia del termotanque cuando este en realidad está encendido. Otro de los problemas se da al intentar estimar correctamente la altura de la potencia. El último de los inconvenientes detectados es cuando el termotanque tiene consumos que no son elevados, es decir, cuando este está encendido por períodos cortos de tiempo debido a una recuperación, en este caso ocurre que es sumamente difícil para el modelo detectar la recuperación.

Capítulo 5. Desagregación no intrusiva de electrodomésticos

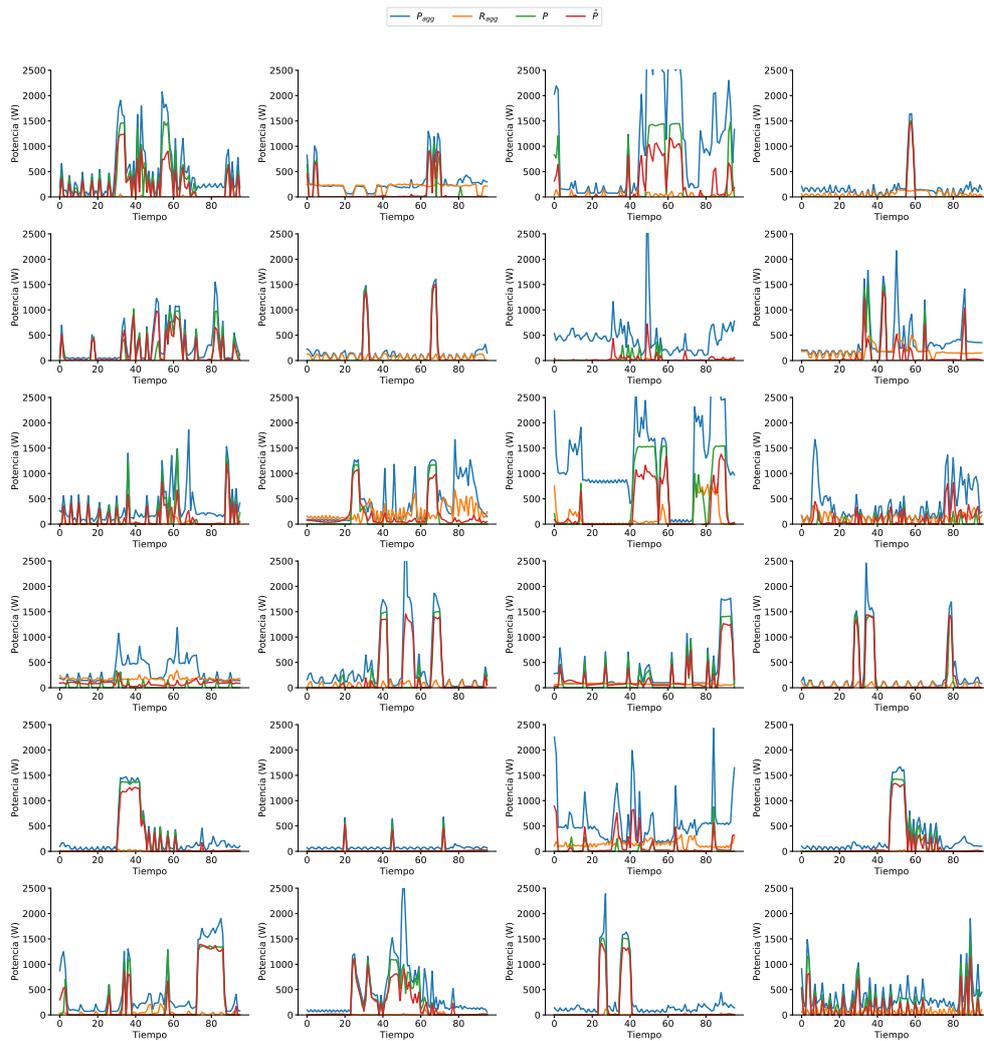


Figura 5.10: Ejemplos de resultados de desagregación de termotanques para el mejor modelo, BiLSTM, sobre el conjunto de test.

5.6.2. Resultados sobre vehículos eléctricos a tasa de 15 minutos

En esta subsección se presentan los resultados para vehículos eléctricos a tasa de 15 minutos. En la Tabla 5.3 se aprecian los valores numéricos de las distintas métricas. Las métricas de clasificación reflejan un incremento significativo respecto a las obtenidas para los termotanques, alcanzando todas ellas valores superiores a 93%. En este caso, por tratarse de un aparato de mayor consumo, el umbral óptimo se encuentra en valores entre los 650W y los 1690W.

En cuanto a las métricas de desagregación, en el mejor modelo se obtiene un valor de MAE cercano a los 100W. Teniendo en cuenta que la carga de un auto eléctrico puede demandar hasta 8kW, un error de tan solo 100W resulta ser un resultado a destacar.

	Entrenamiento						Mejor Umbral
	MAE	RMSE	Accuracy	Precision	Recall	F1-Score	
DAE	318.5	522.0	96.1	92.5	89.0	90.7	-
FC-DAE	144.3	262.1	98.1	98.1	93.2	95.6	-
BiLSTM	89.6	209.4	98.3	98.4	93.6	96.0	-
Seq2Seq	243.6	418.4	97.2	94.6	92.1	93.3	-
ResNet	136.2	270.0	98.0	98.2	92.6	95.4	-
InceptionTime	94.1	181.4	98.7	97.6	96.3	96.9	-
Mean	1925.2	2525.5	-	-	-	-	-
	Validación						Mejor Umbral
	MAE	RMSE	Accuracy	Precision	Recall	F1-Score	
DAE	328.2	538.7	96.1	91.9	90.2	91.0	1690
FC-DAE	164.9	301.5	98.0	97.5	93.3	95.3	1260
BiLSTM	100.3	243.7	98.1	97.6	93.6	95.6	1420
Seq2Seq	261.5	453.0	96.7	93.0	92.1	92.5	1430
ResNet	151.7	290.7	98.0	98.3	92.6	95.4	1520
InceptionTime	105.1	202.6	98.5	96.9	96.4	96.7	650
Mean	1959.8	2574.9	-	-	-	-	-

Tabla 5.3: Resultados de desagregación a tasa de 15 minutos sobre vehículos eléctricos.

Al comparar los distintos modelos, se observa que InceptionTime se desempeña mejor en las métricas de clasificación, lo que indica que esta arquitectura es más efectiva en la identificación de los estados de encendido y apagado de los electrodomésticos. En cuanto a las métricas de desagregación, InceptionTime tiene un mejor desempeño en términos de RMSE lo que sugiere que este modelo tiene menos presencia de outliers (valores en potencia muy alejados de los reales). Por otro lado, BiLSTM muestra un mejor desempeño en términos de MAE, lo que indica que a pesar de tener más outliers este enfoque es más preciso en términos de la norma L1.

En la Figura 5.11, se pueden observar ejemplos de los distintos modelos aplicados a la desagregación de vehículos eléctricos. A simple vista, las mayores diferencias entre estos modelos radican en que InceptionTime y BiLSTM tienen una mayor capacidad para aprender las formas rectangulares de las señales, lo que

Capítulo 5. Desagregación no intrusiva de electrodomésticos

les permite estimar mejor el patrón real de consumo de energía de un vehículo eléctrico.

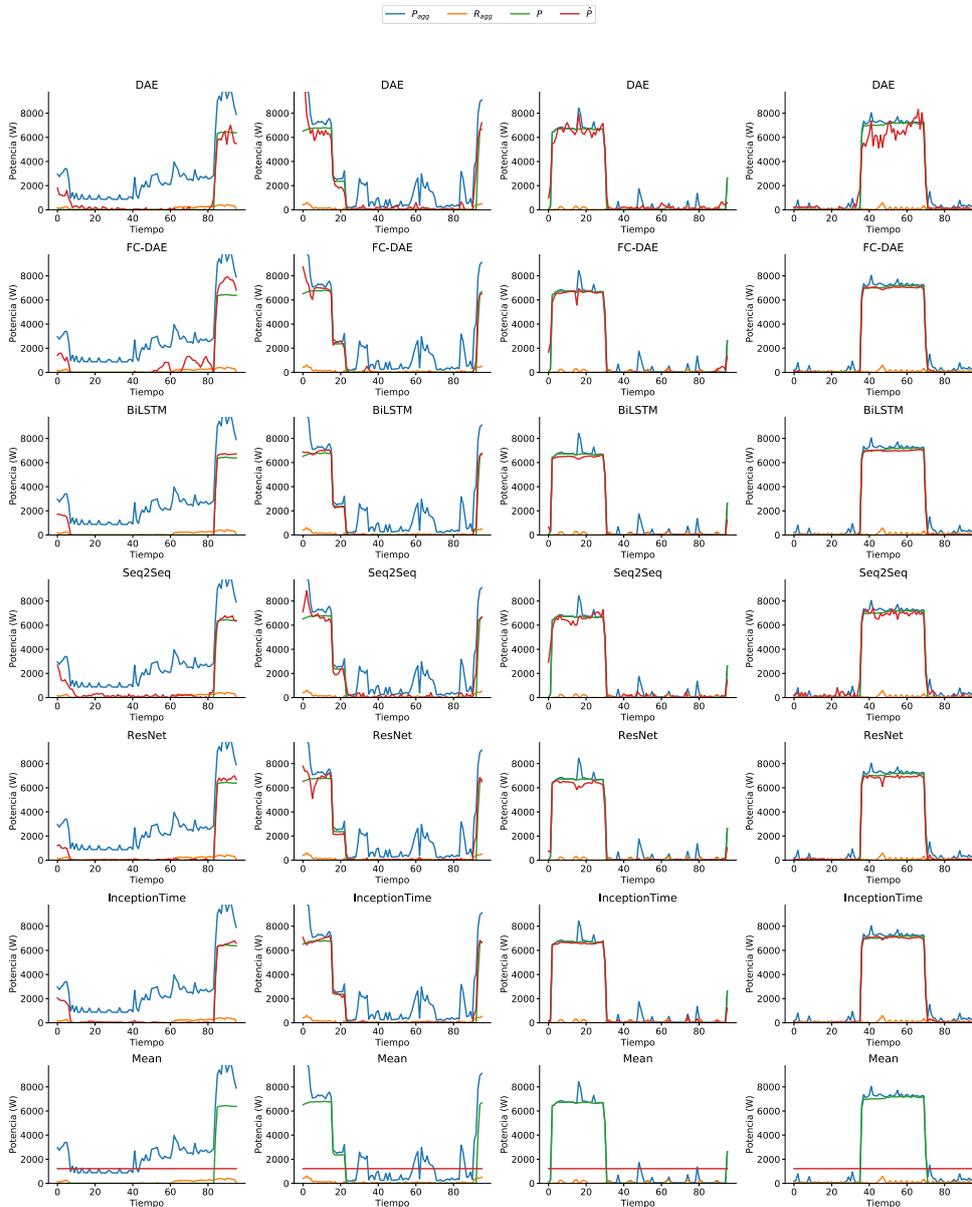


Figura 5.11: Ejemplos de resultados de desagregación de vehículos eléctricos para todos los modelos a tasa de 15 minutos. En cada fila se tienen resultados para el mismo modelo, en cada columna se tiene las mismas señales para comparar los resultados.

Al igual que para los modelos sobre los termotanques, la arquitectura que se comporta mejor en MAE sobre el conjunto de validación es BiLSTM, por lo tanto es nuevamente la escogida como la mejor arquitectura.

En la Figura 5.12 se observa la curva ROC para este modelo. En la misma se aprecia que se tienen excelentes resultados para un amplio rango de umbrales,

	Entrenamiento	Validación	Test
MAE	89.6	100.3	100.9
RMSE	209.4	243.7	291.8
Accuracy	98.3	98.1	98.0
Precision	98.4	97.6	97.5
Recall	93.6	93.6	92.6
F1-Score	96.0	95.6	95.0

Tabla 5.4: Resultados de desagregación 15 minutal sobre vehículos eléctricos.

con una AUC de 0,98. Esta forma de la curva implica que al moverse cercano al quiebre, variando levemente el umbral se pueden mejorar la tasa de verdaderos positivos sin aumentar demasiado los falsos positivos.

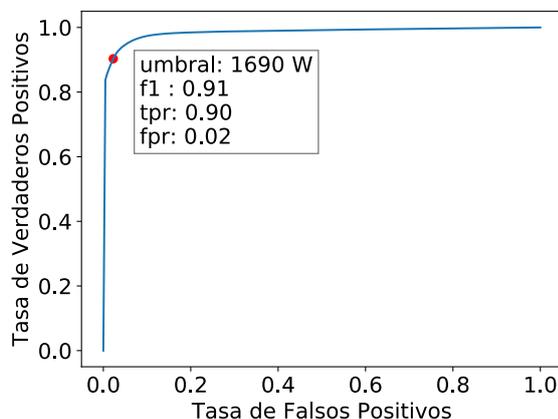


Figura 5.12: Curva ROC para la desagregación a tasa de 15 minutos sobre vehículos eléctricos en el modelo BiLSTM. En rojo el punto de funcionamiento óptimo que maximiza el puntaje F1.

Además, se calculan las métricas sobre el conjunto de test, para el cual se tienen los resultados de la Tabla 5.4. Al comparar los resultados entre los distintos conjuntos de datos, no se aprecia una gran diferencia en los valores de las métricas, lo que indica la ausencia de sobreajuste en los modelos. Esta observación es importante ya que sugiere que los modelos son capaces de generalizar adecuadamente.

En la Figura 5.13 se observan varios ejemplos de las señales obtenidas por el modelo BiLSTM. En la mayoría de los casos se tiene muy buenos resultados, ocurriendo que en algunos casos no se logra detectar precisamente la altura.

Tanto los resultados visuales como numéricos indican que es más fácil para este tipo de modelos aprender a desagregar electrodomésticos de alto consumo, puesto que estos sobresalen sobre el resto de consumos de los demás electrodomésticos.

Capítulo 5. Desagregación no intrusiva de electrodomésticos

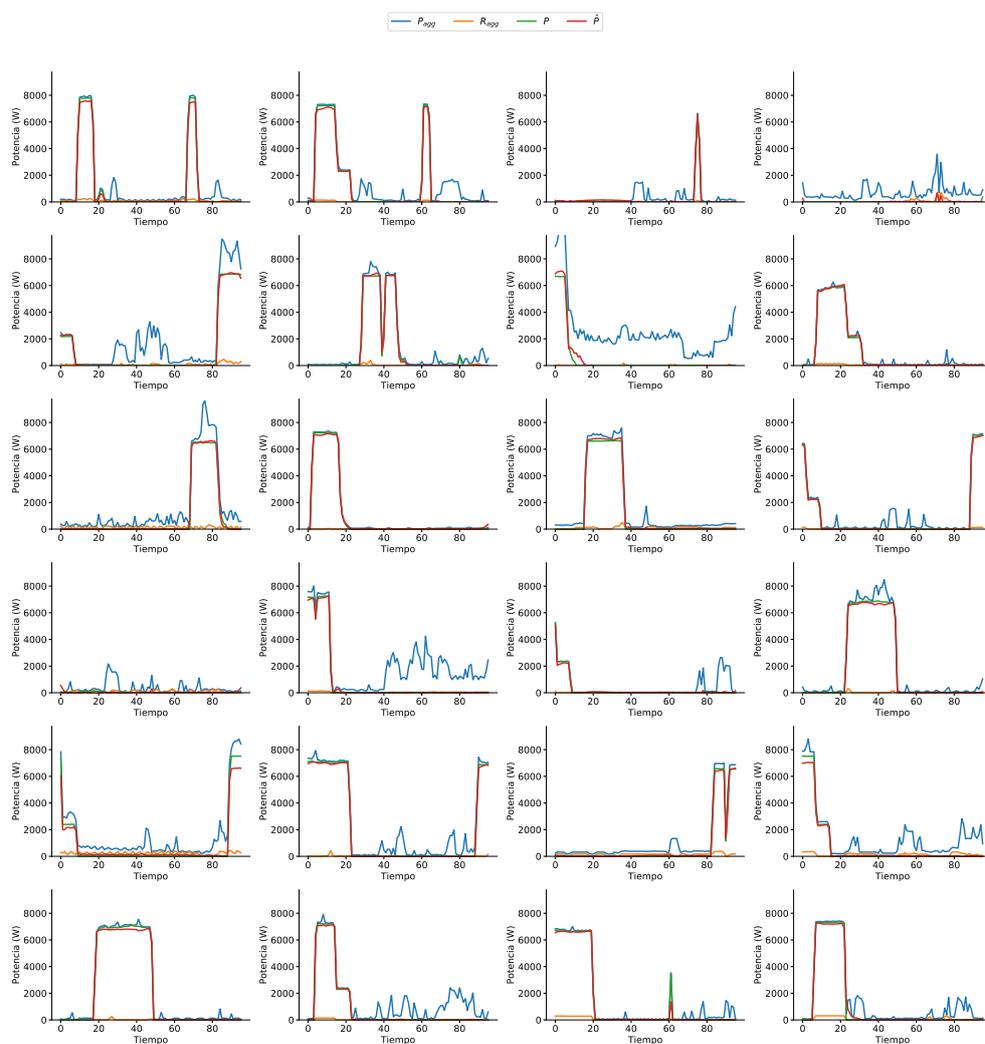


Figura 5.13: Ejemplos de resultados de desagregación de vehículos eléctricos para el mejor modelo, BiLSTM, sobre el conjunto de test.

5.6.3. Resultados sobre termotanques a tasa de 1 minuto

En esta subsección se presentan los resultados al desagregar termotanques a una tasa de 1 minuto. Dado que la salida de los modelos son de tamaños distintos respecto a los experimentos anteriores, los valores de las métricas no son directamente comparables. Si bien es de esperar que ante una tarea más difícil los resultados sean peores, igualmente constituyen un insumo válido debido a que se está resolviendo otro tipo de problema.

En la Tabla 5.5 se muestran los resultados para el conjunto de entrenamiento y validación. Los valores de MAE para el mejor modelo, BiLSTM, son aproximadamente $100W$. A su vez, en las métricas de estado el recall es mayor que el precision para el mejor umbral, lo que lleva a una mayor existencia de falsos positivos que de falsos negativos, situándose estas métricas en torno al 70% y al 78%, respectivamente.

Los umbrales óptimos obtenidos son en torno a los $400W$, mayores a los de la tasa de 15 minutos, lo cual es lógico en la medida que los termotanques a esta tasa alcanzan valores más elevados, al no sufrir del efecto del promediado por el submuestreo.

	Entrenamiento						Mejor Umbral
	MAE	RMSE	Accuracy	Precision	Recall	F1-Score	
DAE	244.8	402.9	53.9	14.0	62.2	22.9	-
FC-DAE	145.4	305.5	90.9	57.0	68.7	62.3	-
BiLSTM	99.4	250.7	93.9	70.0	77.6	73.6	-
Seq2Seq	148.0	276.0	93.3	69.3	69.5	69.4	-
ResNet	130.3	287.3	92.0	61.8	72.1	66.6	-
InceptionTime	116.5	268.2	93.2	67.6	72.9	70.2	-
Mean	243.4	405.7	-	-	-	-	-
	Validación						Mejor Umbral
	MAE	RMSE	Accuracy	Precision	Recall	F1-Score	
DAE	249.7	410.5	54.6	15.2	64.8	24.6	150
FC-DAE	155.6	317.2	89.8	54.0	74.0	62.5	360
BiLSTM	103.8	262.4	93.5	69.1	77.8	73.2	380
Seq2Seq	154.2	287.7	92.8	67.6	71.6	69.5	430
ResNet	135.7	295.0	91.4	59.6	76.6	67.0	390
InceptionTime	119.2	273.7	92.9	66.3	76.2	70.9	420
Mean	249.0	414.1	-	-	-	-	-

Tabla 5.5: Resultados de desagregación minutal sobre termotanques.

Nuevamente, el modelo con mejor desempeño en MAE sobre el conjunto de validación es el BiLSTM, con la particularidad adicional que también lo es para otras métricas.

En la Figura 5.14, se pueden observar ejemplos de la desagregación para los distintos modelos. Con fines de visualización, la señal de entrada a la red (P_{agg} y R_{agg}) es remuestreada a una tasa de un minuto, lo que provoca un efecto de escalonado. Los resultados visuales obtenidos son correctos en los casos en que la

Capítulo 5. Desagregación no intrusiva de electrodomésticos

duración de encendido del termotanque es considerable. Sin embargo, cuando el termotanque se enciende por un intervalo menor a 15 minutos, se da el caso de que la serie temporal del termotanque es de mayor valor a la señal agregada, siendo en estos casos cuando la desagregación de los modelos se desempeña peor.

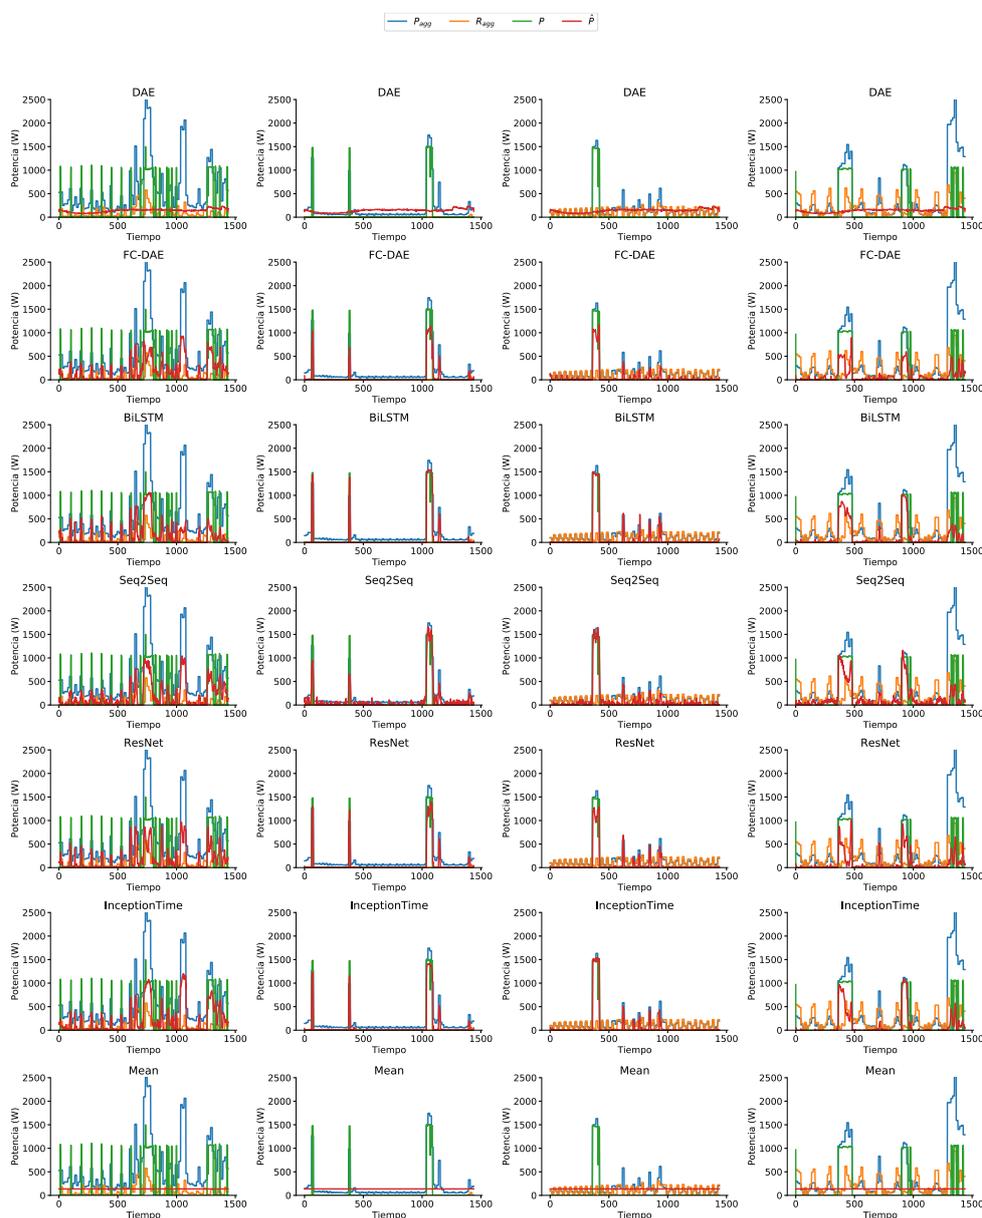


Figura 5.14: Ejemplos de resultados de desagregación de termotanques para todos los modelos a tasa de 1 minuto. En cada fila se tienen resultados para el mismo modelo, en cada columna se tienen las mismas señales para comparar los resultados.

La curva ROC del mejor modelo se puede observar en la Figura 5.15, la misma tiene una AUC de 0,96.

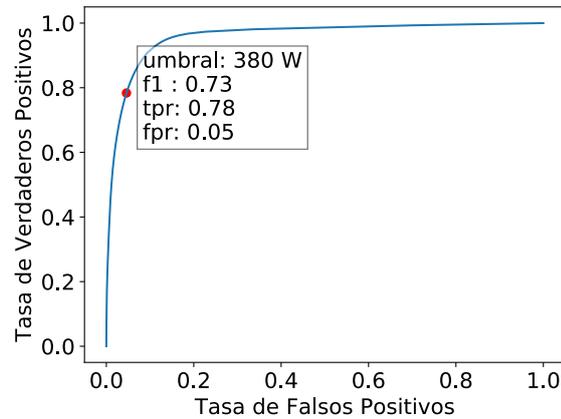


Figura 5.15: Curva ROC para la desagregación a tasa de 15 minutos sobre termotanques en el modelo BiLSTM. En rojo el punto de funcionamiento óptimo que maximiza el puntaje F1.

En la Tabla 5.6 se muestran los resultados sobre el conjunto de test. Al igual que los casos anteriores, se observa una caída en el desempeño respecto a los conjuntos de entrenamiento y validación, pero no lo suficiente como para considerar que exista sobreajuste.

	Entrenamiento	Validación	Test
MAE	99.4	103.8	115.2
RMSE	250.7	262.4	279.2
Accuracy	93.9	93.5	92.5
Precision	70.0	69.1	66.1
Recall	77.6	77.8	74.9
F1-Score	73.6	73.2	70.2

Tabla 5.6: Resultados de desagregación minutal sobre termotanques.

Por último, en la Figura 5.16, se presentan varios ejemplos de resultados para la arquitectura BiLSTM. En estos, se observa nuevamente el problema de que el modelo tiene dificultades para desagregar los encendidos de corta duración del termotanque.

Capítulo 5. Desagregación no intrusiva de electrodomésticos

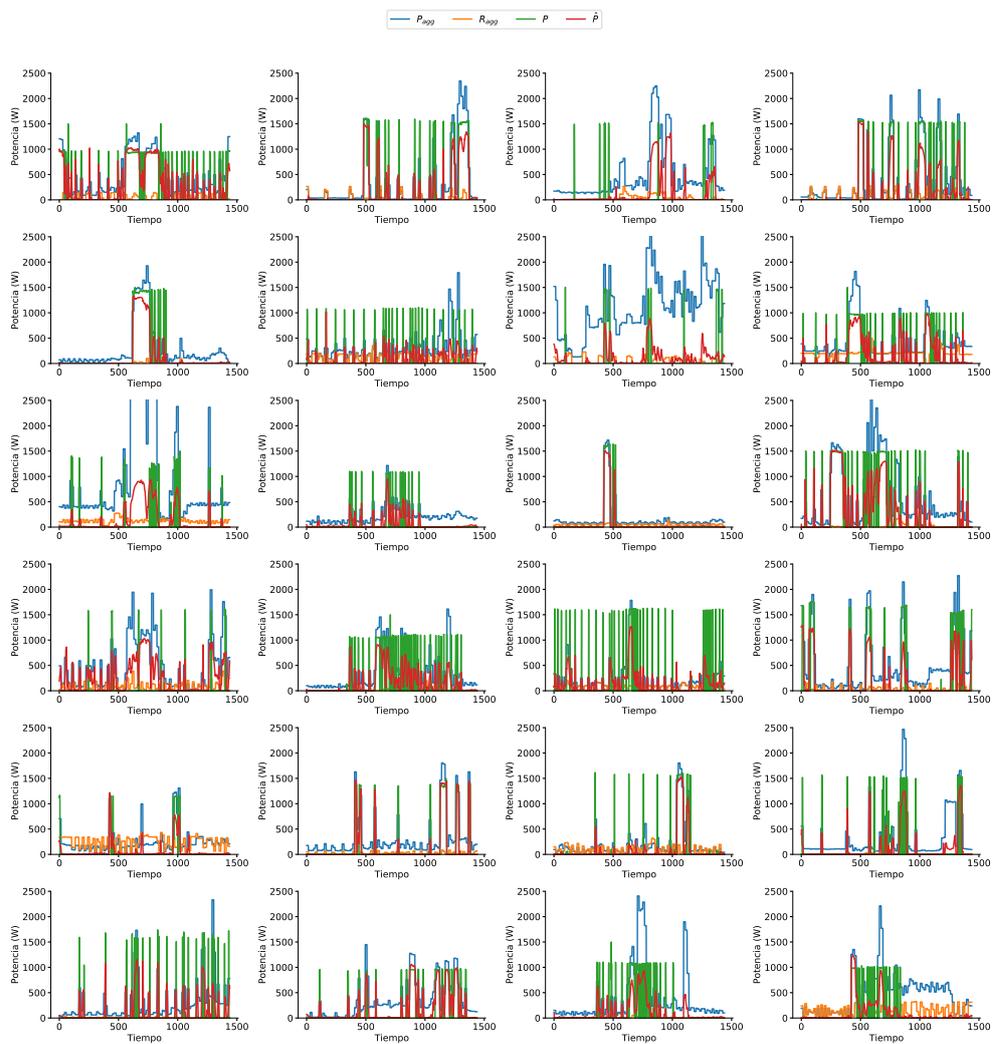


Figura 5.16: Ejemplos de resultados de desagregación de termotanques a tasa de 1 minuto para el mejor modelo, BiLSTM, sobre el conjunto de test.

5.6.3.1. Mejora del modelo a tasa de 15 minutos sobre termotanques

Los valores numéricos del F1-score y MAE a tasa de 1 minuto no son tan favorables en comparación con los obtenidos a tasa de 15 minutos. Esta diferencia se debe a la doble tarea que debe realizar la red neuronal: desagregar y aumentar la resolución, debido a que la resolución de la entrada es menor que la resolución de la salida. En la Figura 5.5, se presentó una solución para utilizar el modelo a tasa de 1 minuto para desagregar a tasa de 15 minutos.

En la Tabla 5.7, se muestran los resultados de las métricas para el modelo a tasa de 1 minuto promediado, junto con los resultados para el modelo a tasa de 15 minutos presentados en la Tabla 5.2 de la Sección 5.6.1. Los resultados indican una disminución de aproximadamente $4W$ en el MAE en todos los conjuntos de datos, así como un incremento en la mayoría de las métricas de estado. Además, sugieren que el supuesto de utilizar más datos para entrenar el algoritmo representa una mejora en el rendimiento.

	Entrenamiento		Validación		Test	
	Original	Promediado	Original	Promediado	Original	Promediado
MAE	67.9	63.6	76.7	72.5	84.5	78.9
RMSE	166.6	165.5	188.7	188.0	203.3	199.6
Accuracy	92.7	92.7	92.1	92.3	90.6	90.9
Precision	79.2	77.0	76.3	75.4	74.5	74.0
Recall	85.3	89.4	84.3	88.1	83.9	87.5
F1-Score	82.2	82.7	80.1	81.3	78.9	80.2

Tabla 5.7: Resultados de desagregación 15 minutal sobre termotanques al remuestrear el modelo a tasa de 1 minuto.

La Figura 5.17 ilustra ejemplos de desagregación de este modelo. Visualmente, no se aprecian grandes diferencias, observación que es razonable en la medida que un cambio en MAE de $4W$ es imperceptible como para ser observado en las figuras.

Capítulo 5. Desagregación no intrusiva de electrodomésticos

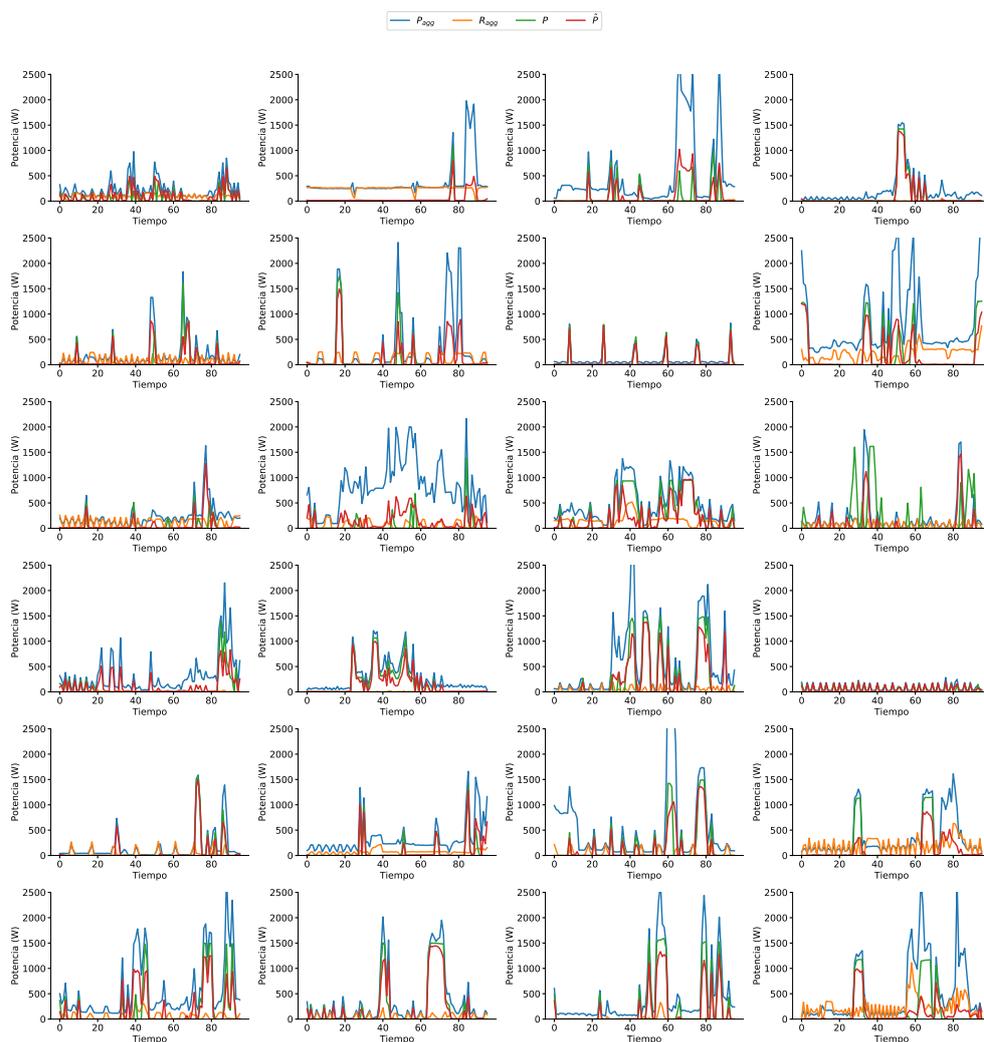


Figura 5.17: Ejemplos de resultados de desagregación de termotanques a tasa de 15 minutos a partir de pos-procesar la salida del modelo BiLSTM a tasa de 1 minuto.

5.7. Comparación con otros trabajos

Para fines comparativos, se utiliza el trabajo [68] que presenta un enfoque para la desagregación de termotanques en Costa Rica basado en reglas. Este trabajo es similar al presentado aquí, aunque es necesario mencionar que no es directamente comparable debido a que solo se reportan resultados a una tasa de 15 minutos para un hogar con medidas durante 4 semanas, presentando poca validez estadística. Además, los termotanques utilizados en Costa Rica, con potencias cercanas a $3000W$, tienen valores más elevados que los de Uruguay, donde las potencias rondan los $1000W$. Asimismo, se trata de una base de datos propietaria, lo que impide acceder a los datos utilizados.

A pesar de estas diferencias, se reporta un MAE de $55W$, que es muy cercano al reportado aquí de $63W$. Esto demuestra que los resultados obtenidos son similares

5.7. Comparación con otros trabajos

a los presentados en otro trabajo del mismo tenor.

En cuanto a los vehículos eléctricos, en [69] se presentan resultados realizados en Austin y Texas, Estados Unidos. Este trabajo tampoco es directamente comparable debido a que los vehículos son de diferentes marcas y los patrones de consumo de los usuarios son diferentes a los de Uruguay. Además, utilizan la base de datos Dataport [93], que cuenta con más de 1500 hogares con vehículos medidos, pero no está disponible públicamente, lo que imposibilita el acceso a los datos. Sin embargo, es el trabajo más similar y reportan un MAE de $76W$ a una tasa de 15 minutos al entrenar y testear sobre hogares de Austin, y $201W$ al entrenar sobre hogares de Austin y testear sobre hogares de Texas. En este trabajo, se reportó un MAE de $100W$ incluyendo hogares de diferentes partes del país, lo que nos indica que los resultados alcanzados se encuentran en un rango razonable en comparación con el estado del arte.

Capítulo 6

Puesta en producción y aplicaciones

En este capítulo se presenta la puesta en producción llevada a cabo por el equipo técnico de Consumo Inteligente de UTE (CI-UTE). A través de la colaboración entre el grupo CI-UTE y FING, se desarrollaron y desplegaron algoritmos de inteligencia artificial para abordar distintos problemas relacionados con el negocio. Entre estos algoritmos se incluyen el clasificador de electrodomésticos y el desagregador de consumo de electrodomésticos descritos en capítulos anteriores. Asimismo, se exponen una serie de aplicaciones junto con experimentos que ilustran el potencial de los modelos con el fin de abordar otros tipos de tareas de interés en el sector productivo.

6.1. Identificación de electrodomésticos sobre clientes de UTE

La empresa UTE tiene desplegados medidores intrusivos en un conjunto de clientes que se encargan de registrar el consumo de diversos electrodomésticos, tales como termotanques, aires acondicionados, heladeras, microondas y bombas de calor, entre otros. Por lo tanto, se utiliza el clasificador desarrollado para determinar qué tipo de electrodoméstico está conectado al medidor intrusivo, y así corroborar que se está registrando el consumo del dispositivo deseado y no de otro electrodoméstico de manera incorrecta.

En el sitio web interno de CI-UTE se creó una plataforma en la que se pueden visualizar los resultados de la clasificación de los electrodomésticos mediante el modelo implementado. La Figura 6.1 muestra una captura de pantalla de la plataforma con las predicciones del clasificador aplicadas a datos de clientes de UTE.

En la Figura 6.2, se muestra otra captura de la plataforma donde se puede observar el comportamiento global del clasificador. Se pueden apreciar dos clasificadores, denominados FING_V1 y FING_V2. Estos corresponden a dos versiones del modelo ResNet a tasa de un minuto entrenados en diferentes etapas del convenio y, por ende, con diferentes volúmenes de datos. La versión FING_V2 coincide con el modelo cuyos resultados se mostraron en el Capítulo 4.6.

Capítulo 6. Puesta en producción y aplicaciones

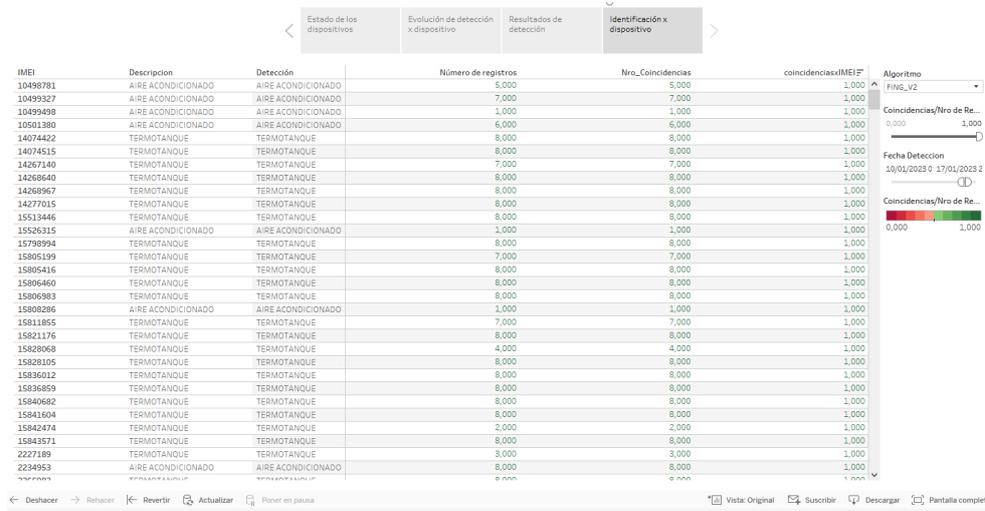


Figura 6.1: Plataforma de clasificación de electrodomésticos desarrollada por el equipo de CI-UTE. Figura proporcionada por el grupo de CI-UTE.



Figura 6.2: Comportamiento global de los clasificadores en la plataforma de CI-UTE. Figura proporcionada por el grupo de CI-UTE.

En la Tabla 6.1 y en la Tabla 6.2 se presentan los resultados para los termotanques y aires acondicionados reportados por el grupo CI-UTE, respectivamente. Se observa que, en el caso de los termotanques, 446 de los 447 fueron detectados correctamente todos los días. Por otro lado, en el caso de los aires acondicionados, 15 unidades fueron identificadas correctamente el 100% de los días, 7 unidades presentaron un desempeño entre el 95% y 97%, y 3 unidades mostraron un rendimiento inferior, con tasas de detección que oscilan entre el 17% y el 80%. Los resultados indican que en producción el modelo se comporta de forma satisfactoria y similar a los experimentos ya realizados, lo cual reafirma el poder de generaliza-

6.2. Desagregación de consumo de una subestación de UTE

Cantidad de termotanques	Tasa de acierto
446	100 %
1	20 %

Tabla 6.1: Comparación entre la cantidad de termotanques y la tasa de acierto del algoritmo en producción. Datos proporcionados por el grupo de CI-UTE.

Cantidad de aires acondicionados	Tasa de acierto
15	100 %
7	95 % - 97 %
3	17 % - 80 %

Tabla 6.2: Comparación entre la cantidad de aires acondicionados y la tasa de acierto del algoritmo en producción. Tabla proporcionada por el grupo de CI-UTE.

ción de los modelos al utilizar nuevos datos.

6.2. Desagregación de consumo de una subestación de UTE

El algoritmo de desagregación del consumo de termotanques se empleó para determinar el nivel de consumo de estos dispositivos en una subestación comprometida, en la cual era crucial reducir la demanda. Se quería evaluar cuánto del consumo en dicha subestación correspondía a los termotanques, ya que de ser significativo, se podría considerar comandar, bajo autorización de los clientes, el funcionamiento de estos dispositivos para aliviar la demanda.

Para llevar a cabo esta tarea se tomaron las curvas de consumo de cada cliente correspondiente a la subestación y se aplicó el desagregador modelo BiLSTM a tasa de 15 minutos, obteniendo así la curva de consumo desagregada del termotanque por cliente.

En la Figura 6.3, se puede observar el resultado de la ejecución del algoritmo. La curva roja representa el consumo agregado de todos los suministros correspondientes a la subestación, mientras que la curva azul muestra la suma de todos los termotanques desagregados de la subestación. A partir de los resultados obtenidos, se concluyó que el nivel de consumo de termotanques era relevante, por lo que se procedió a instalar medidores intrusivos en algunos clientes, derivando en una disminución de la demanda de la subestación.

Capítulo 6. Puesta en producción y aplicaciones

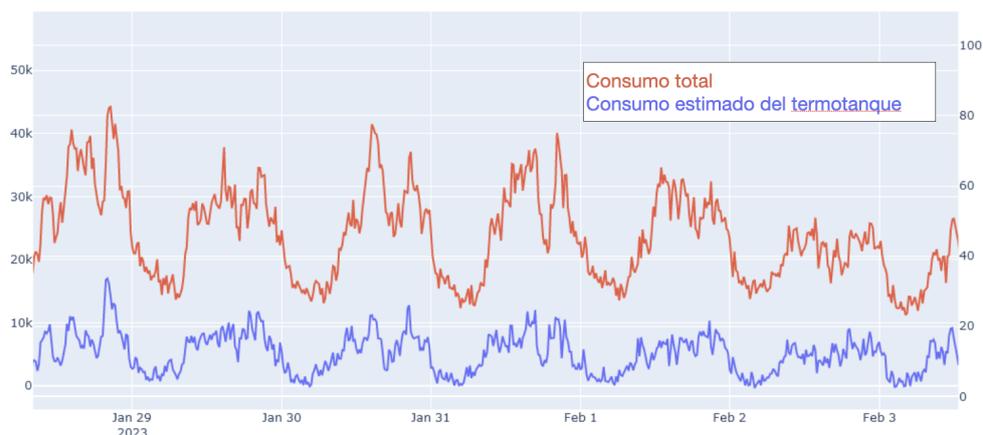


Figura 6.3: Resultados de la ejecución del algoritmo de desagregación del consumo de termotanques a nivel de una subestación de UTE. Figura proporcionada por el grupo de CI-UTE.

6.3. Estimación de la facturación mensual correspondiente a un electrodoméstico

En UTE, la facturación de la energía se realiza de forma mensual. Sin embargo, a través de los algoritmos de desagregación es posible estimar cuánto del consumo mensual corresponde al vehículo eléctrico y al termotanque, lo que le permite al ente energético proporcionar al usuario una factura desagregada por tipo de consumo.

El proceso para estimar la energía consumida por un electrodoméstico específico para un cliente a lo largo de un mes se resume en los siguientes pasos:

1. Tomar la serie temporal de consumo mensual del cliente.
2. Dividir la serie por días.
3. Aplicar el modelo BiLSTM de desagregación a cada uno de los días.
4. Concatenar las desagregaciones diarias.
5. Sumar el consumo mensual resultante y convertirlo a las unidades de kWh .

Reporte sobre los termotanques

Para comprender mejor los resultados obtenidos, es necesario analizar la distribución del consumo mensual de los termotanques. La Figura 6.4 muestra el histograma del consumo en kWh de los termotanques a nivel mensual, en un rango que oscila entre algunos pocos kWh hasta aproximadamente $250kWh$.

Al aplicar el procedimiento de estimación de consumo mensual de energía, se obtienen los errores presentados en la Figura 6.5. La figura de la izquierda muestra los resultados del error absoluto en la asignación de energía, donde un

6.3. Estimación de la facturación mensual correspondiente a un electrodoméstico

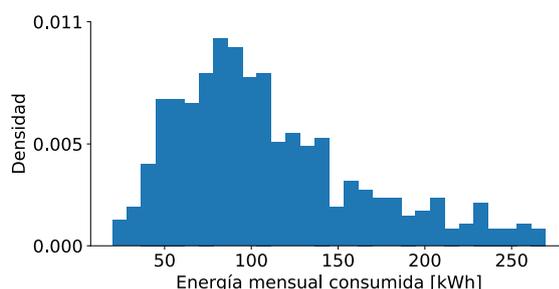


Figura 6.4: Histograma de consumo mensual de los termotanques en Uruguay.

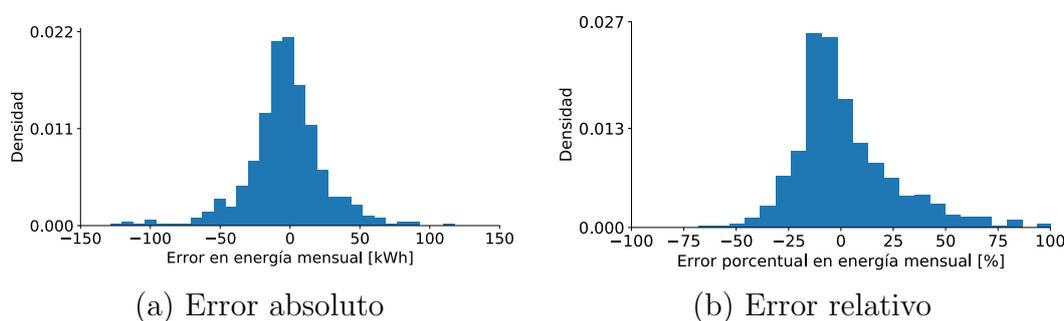


Figura 6.5: Errores de estimación de consumo de energía mensual para termotanques.

valor positivo indica una sobreestimación de energía y un valor negativo indica una subestimación. Por otro lado, en la figura de la derecha se muestra el error porcentual relativo.

Los resultados indican que los errores se concentran en torno de cero, con una media de $-3,2kWh$ y una desviación estándar de $27,8kWh$. Además, se observa que los errores porcentuales también se concentran próximo a cero.

6.3.0.1. Prueba en producción sobre clientes

El grupo CI-UTE realizó pruebas sobre algunos clientes para evaluar el desempeño del algoritmo de desagregación. En la Figura 6.6, se visualiza un diagrama de cajas de los errores a lo largo de un año para un cliente particular. En la mayoría de los meses, el error medio mensual se mantiene por debajo del 20%.

Para otro cliente, el error es menor, como se muestra en la Figura 6.7, donde el error medio mensual está siempre por debajo del 10%. La magnitud de estos errores depende de la composición del resto de los electrodomésticos en la vivienda en cuestión.

Capítulo 6. Puesta en producción y aplicaciones

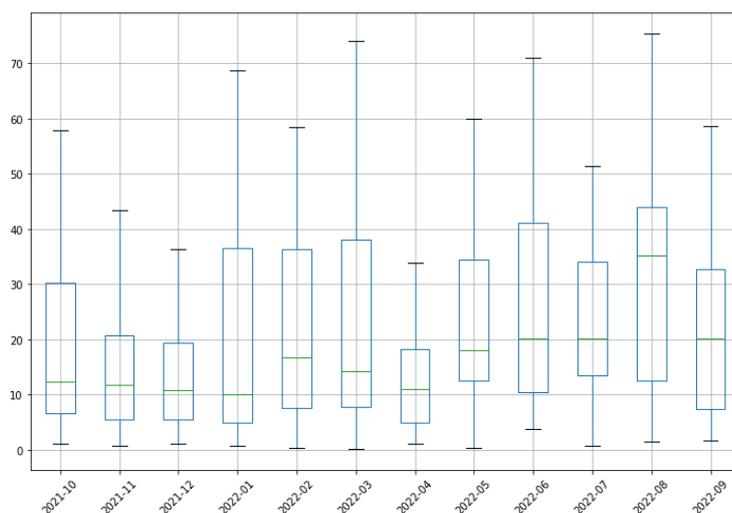


Figura 6.6: Diagrama de cajas de los errores en la desagregación del consumo de termotanques a lo largo de un año para un cliente particular. Figura proporcionada por el grupo de CI-UTE.

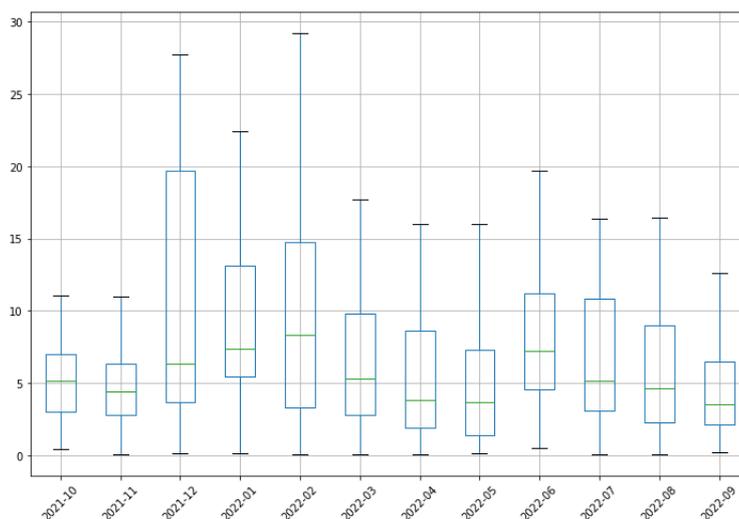


Figura 6.7: Diagrama de cajas de los errores en la desagregación del consumo de termotanques a lo largo de un año para un cliente particular. Figura proporcionada por el grupo de CI-UTE.

Reporte sobre los vehículos eléctricos

Para los vehículos eléctricos se realizó un análisis análogo al de los termotanques. En la Figura 6.8 se muestra el histograma de consumo de energía mensual para estos electrodomésticos.

Al aplicar el procedimiento de estimación del consumo mensual de energía, los resultados obtenidos indican valores concentrados en torno a cero, como se puede apreciar en la Figura 6.9. La media obtenida es de $-0,4kWh$ y la desviación estándar de $7,3kWh$. Además, se aprecia que el error porcentual es menor al 10%.

6.4. Determinar presencia de un termotanque

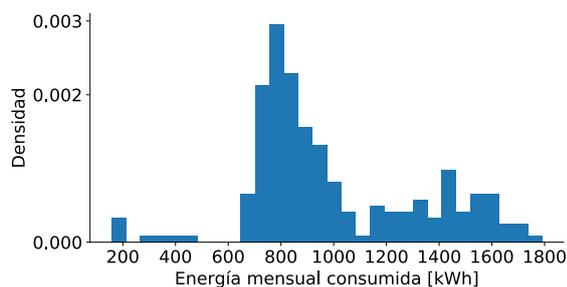


Figura 6.8: Histograma de consumo mensual de los vehículos eléctricos en Uruguay.

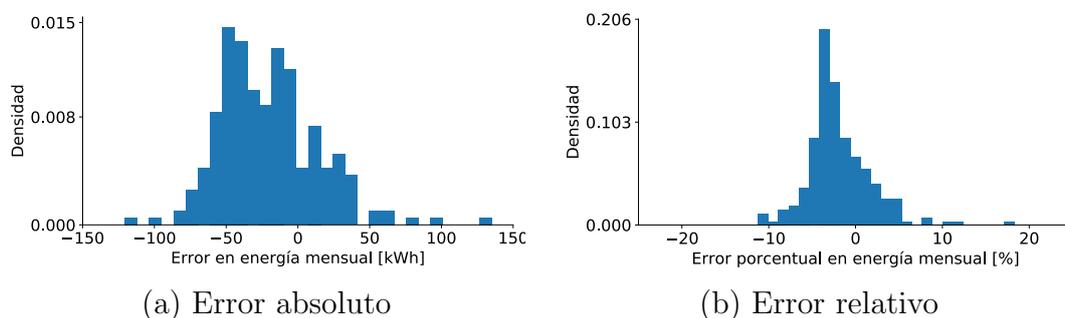


Figura 6.9: Errores de estimación de consumo de energía mensual para vehículos eléctricos.

6.4. Determinar presencia de un termotanque

El grupo de CI-UTE llevó a cabo otro experimento que consistió en desagregar el consumo del termotanque por día a partir de la curva de consumo total de una vivienda durante un período de aproximadamente 1 año. Dado que se cuenta con la submedición del consumo del termotanque, se restó este consumo del consumo total de la vivienda, obteniendo así el consumo de una casa sin termotanque. Posteriormente, se aplicó el desagregador de consumo de termotanques a esta curva, cuyo resultado ideal debería ser la serie nula.

Se aplicó el clasificador por día tanto al consumo desagregado con termotanque como al consumo desagregado sin termotanque para determinar si la curva desagregada correspondía a un termotanque o no. El clasificador proporciona un valor de salida para cada tipo de electrodoméstico soportado que puede considerarse como una probabilidad. Se construyeron histogramas con estas probabilidades y para ambos casos de desagregación.

En la Figura 6.10, se pueden observar ambos histogramas, donde el azul corresponde a la probabilidad de ser termotanque en el caso de la desagregación de la casa sin termotanque, y la curva naranja representa la probabilidad de ser termotanque en el caso de la desagregación de la casa con termotanque. A partir de los resultados se puede inferir que, utilizando el clasificador, el desagregador funciona correctamente, ya que desagrega curvas que se asemejan más a termotanques cuando hay uno que cuando no lo hay.

Capítulo 6. Puesta en producción y aplicaciones

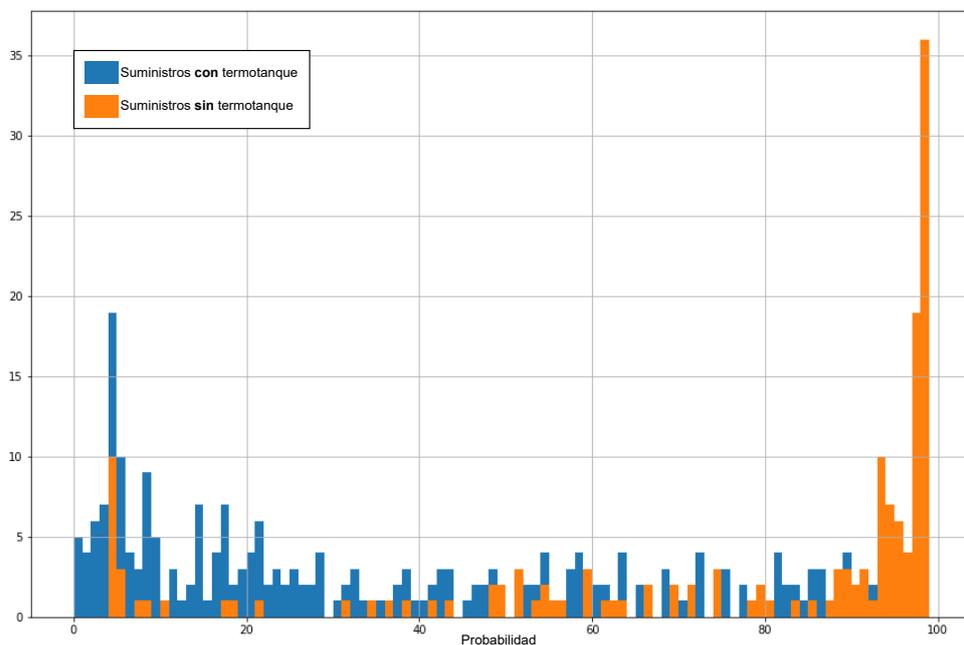


Figura 6.10: Histogramas de la probabilidad de ser termotanque. Figura proporcionada por el grupo de CI-UTE.

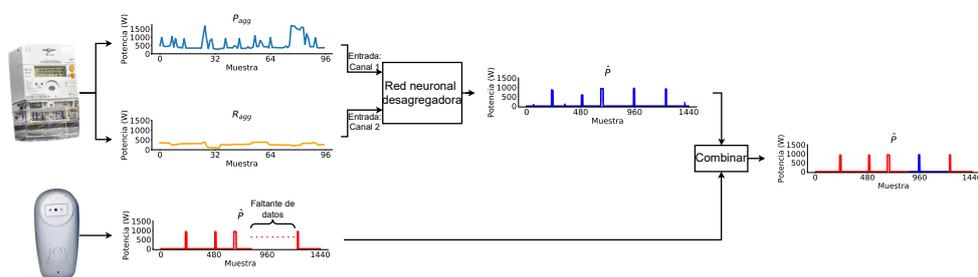


Figura 6.11: Esquema para imputar datos faltantes del medidor intrusivo a partir de la desagregación de consumo del medidor inteligente.

6.5. Otras aplicaciones

A lo largo de las diversas reuniones con el grupo CI-UTE, se han propuesto diversas aplicaciones potenciales basadas en los algoritmos ya transferidos. Estas aplicaciones podrían ser implementadas en producción por CI-UTE en etapas posteriores.

En primer lugar, una necesidad de UTE radica en abordar los datos faltantes en medidores intrusivos de termotanques, los cuales pueden surgir debido a problemas en la adquisición o comunicación de la información. Para solucionar esta situación, es posible hacer uso del desagregador para rellenar los huecos en los datos de consumo. Para esto se puede aplicar el desagregador sobre los datos del medidor inteligente y así estimar los valores faltantes. La Figura 6.11 ilustra este proceso.

6.5. Otras aplicaciones

Por otro lado, en un futuro podría resultar útil emplear el modelo desagregador de vehículos eléctricos, en función de la necesidad de UTE de facturar de manera diferenciada su consumo. En este trabajo, se abordó una primera aproximación al problema, demostrando que es posible detectar y desagregar su consumo con alta precisión, lo que a su vez nos indica que la facturación específica del consumo de vehículos eléctricos es una aplicación prometedora. Además, si la tendencia continúa, es probable que el consumo de vehículos eléctricos represente una parte significativa del consumo eléctrico residencial de los clientes. En este contexto, el uso de herramientas como el desagregador podría permitir influir de manera eficiente en la demanda energética de los clientes y optimizar la gestión y distribución de la energía.

Capítulo 7

Conclusiones

Este trabajo se centró en la identificación y desagregación de electrodomésticos a *muy-baja-frecuencia*. En particular, se aplicaron algoritmos sobre datos uruguayos, con énfasis en los resultados referentes a termotanques y vehículos eléctricos.

Se propuso un enfoque para la identificación de electrodomésticos basado en el análisis de las curvas de consumo de potencia activa, empleando técnicas de aprendizaje automático mediante clasificadores multiclase sobre datos adquiridos a una tasa de 1 minuto. Los resultados obtenidos demuestran que este enfoque permite la identificación de termotanques con alta precisión.

Se concluye que el uso de redes neuronales convolucionales es relevante para la tarea de identificación de electrodomésticos. En particular, la arquitectura ResNet demostró el mejor desempeño tanto en la tarea de clasificación multiclase como en la tarea de clasificación binaria, alcanzando un F1-Score de 0,728 y 0,961, respectivamente sobre los datos de test. Por otro lado, los modelos no convolucionales no lograron alcanzar un desempeño adecuado en ninguna de las tareas evaluadas.

Se identificó que la resolución temporal de las señales de potencia es un factor crítico para la identificación precisa de electrodomésticos. Se observó que, para tasas de muestreo reducidas, más lentas que una muestra cada 20 minutos aproximadamente, el desempeño del modelo se deteriora considerablemente, alcanzando valores de F1-Score insatisfactorios de entre 0,4 y 0,6.

Además, se realizó un análisis de las características de la última capa del modelo de identificación ResNet para visualizar la distribución de los electrodomésticos en dos dimensiones, encontrando agrupamientos de puntos que son consistentes con los resultados obtenidos en la matriz de confusión. Este análisis proporcionó una representación visual del desempeño del modelo en la tarea de clasificación multiclase.

En general, se puede concluir que el enfoque propuesto es efectivo para la identificación de termotanques a partir de las curvas de consumo de potencia activa. Este enfoque tiene potencial para ser extendido a la identificación de otros electrodomésticos.

Por otro lado, se presentó un estudio sobre la aplicación de redes neuronales para la desagregación de consumo de energía eléctrica en electrodomésticos a muy baja frecuencia, utilizando datos de hogares en Uruguay. Se implementaron dife-

Capítulo 7. Conclusiones

rentes arquitecturas de redes neuronales a dos tasas de muestreo, 1 minuto y 15 minutos, y se evaluaron con las métricas comúnmente empleadas en el campo de NILM. Los resultados obtenidos indican que los modelos basados en redes recurrentes de tipo BiLSTM son los que obtienen mejores resultados en términos de MAE.

Se observó que la incorporación de datos con una tasa de 1 minuto para desagregar a una tasa de 15 minutos resulta en una mejora en los resultados obtenidos. Esto se atribuye a que el proceso de desagregación se realiza con una mayor cantidad de datos, lo cual es beneficioso para los modelos implementados. Para esto, se adaptó el modelo con una mayor frecuencia de muestreo, añadiéndole una capa adicional de promediado a la red, lo que permitió desagregar el consumo a una frecuencia más baja. Sin embargo, se concluye que no fue posible, con este enfoque, realizar la desagregación a 1 minuto a partir de la señal a 15 minutos.

Desde un punto de vista comparativo entre la desagregación de termotanques y vehículos eléctricos, se obtuvieron mejores resultados en la desagregación de estos últimos. Esto puede atribuirse a que el ciclo de carga de un vehículo eléctrico posee una mayor potencia y una duración más prolongada, lo que facilita su distinción en la serie de potencia agregada.

Adicionalmente, los resultados de desagregación fueron comparados con otros estudios identificados en el estado del arte, los cuales presentan similitudes en aspectos como tipo de datos, frecuencia, algoritmo y metodología de entrenamiento. Al obtener resultados similares, se puede concluir que el enfoque propuesto está alineado con el estado del arte.

Los experimentos realizados en este estudio sugieren que las redes neuronales son una herramienta valiosa para el monitoreo de cargas, tanto para la tarea de identificación como para la tarea de desagregación.

Por otro lado, se realizó un aporte significativo en la generación y preparación de varias bases de datos nuevas. Se contribuyó a la generación y preparación de bases de datos en un formato estándar llamado NILMTK-HDF. Específicamente, se corrigió el código convertidor de tres bases de datos y se implementó desde cero el código de otras tres bases de datos, incluyendo la base local NILM-UY publicada en [8]. Todo este código se puso a disposición del público mediante repositorios de GitHub.

Además, se llevó a cabo transferencia tecnológica con la empresa UTE, mediante la realización de talleres y reuniones periódicas, así como la disponibilización del código implementado. Esto permitió que UTE aplicara los algoritmos desarrollados en aplicaciones concretas de su interés. En particular, la empresa tiene en producción un clasificador de electrodomésticos, el cual ha presentado buenos resultados. Asimismo, ha utilizado el desagregador de termotanques para resolver situaciones específicas, también con resultados satisfactorios.

Apéndice A

Arquitecturas de redes neuronales

En este apéndice se presentan las arquitecturas de redes neuronales utilizadas tanto para la identificación como para la desagregación de electrodomésticos.

Para la tarea de identificación, se utilizaron implementaciones de la biblioteca TSAI¹ (State-of-the-art Deep Learning library for Time Series and Sequences) [126], la cual contiene arquitecturas del estado del arte para series temporales.

Por otro lado, para la tarea de desagregación, se implementó una biblioteca llamada *nilm_disaggregation_nets*², que posee varias de las arquitecturas del estado del arte para la tarea específica de NILM. También se utilizaron varias arquitecturas presentes en TSAI.

A continuación, se explicará brevemente el concepto detrás de cada arquitectura y se presentará un fragmento de código en Python que muestra cómo obtener la red en la biblioteca PyTorch [127]. Por más detalles se sugiere ir al artículo referenciado para cada arquitectura, así como a la implementación y/o documentación de TSAI o *nilm_disaggregation_nets*.

A.1. Arquitecturas de identificación

En esta sección, se describen las arquitecturas de redes neuronales empleadas para clasificar electrodomésticos en el contexto ILM. La entrada a estos modelos consiste en el consumo de potencia activa muestreada a una tasa de 1 minuto a lo largo de un día, lo que resulta en un solo canal con 1440 muestras. La salida de los modelos es un vector de probabilidades de tamaño igual a la cantidad de electrodomésticos a clasificar (*cant_elecs*).

A.1.1. MLP

La arquitectura *Multi Layer Perceptron* (MLP) [117] utiliza únicamente capas completamente conectadas. Consiste en tratar cada uno de los valores de la serie temporal de potencia como una característica de entrada a la red. La Figura A.1

¹<https://github.com/timeseriesAI/tsai>

²https://github.com/camilomarino/nilm_disaggregation_nets

Apéndice A. Arquitecturas de redes neuronales

ilustra esta arquitectura, cuya entrada son las 1440 neuronas correspondientes a la cantidad de valores de potencia en una serie temporal de un día. Luego, contiene varias capas ocultas y finalmente, la capa de salida con una cantidad de neuronas igual a la cantidad de electrodomésticos que se desea clasificar.

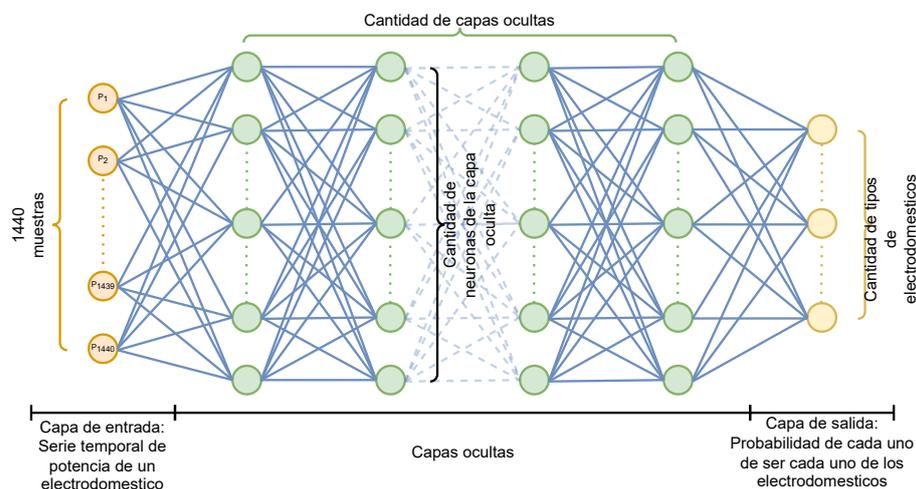


Figura A.1: Arquitectura MLP para clasificación de electrodomésticos.

Específicamente el código correspondiente a esta arquitectura es el siguiente:

```
from tsai.models.MLP import MLP
model = MLP(
    c_in=1,
    c_out=cant_elecs,
    seq_len=1440,
)
```

Este tipo de red neuronal es la más simple de comprender. Sin embargo, una de las desventajas es que estas no explotan las relaciones temporales presentes en las series de tiempo. Esto significa que no son tan eficientes en el procesamiento de características temporales. Además, la cantidad de parámetros se incrementa exponencialmente al agregar unas pocas capas extras.

A.1.2. RNN

Las redes neuronales recurrentes (RNN) son una clase de redes neuronales que se utilizan para procesar secuencias de datos, como series temporales. Estas redes tienen una característica única que las distingue de otras redes neuronales: el *feedback* o retroalimentación, donde la salida de una unidad temporal se alimenta como entrada a la unidad temporal siguiente. La intuición de la RNN es que “recuerda” información pasada y la utiliza para procesar la información actual.

El concepto fundamental de estas redes es el de estado s . La relación entre el estado en el instante $t - 1$ y el instante t se expresa de la siguiente forma:

$$s_t = \tanh(W_{ss}s_{t-1} + W_{sp}P_t + b_s).$$

A.1. Arquitecturas de identificación

Donde W_{sp} , W_{ss} y b_s son los parámetros de la red neuronal que **se comparten en todo instante de tiempo**, es decir, no dependen de t . Por otro lado P_t es la entrada en el instante t , en particular la potencia activa del electrodoméstico. Notar que tanto el estado, como la salida no son escalares, sino que vectores. En Figura A.2 se visualiza las relaciones presentes en la ecuación anterior.

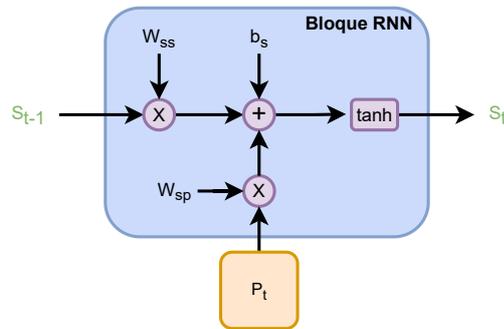


Figura A.2: Esquema de un bloque de una red neuronal recurrente. Donde s_t es el estado y P_t la entrada

La Figura A.3 muestra como se combina el bloque de la RNN a lo largo del tiempo para ser utilizado en el dominio específico de clasificación de electrodomésticos. Las entradas son los valores de potencia en los distintos instantes de tiempo desde 1 hasta 1440, es decir, $P_1, P_2, \dots, P_{1440}$. El bloque RNN es el mismo en todo instante de tiempo y recibe la entrada en ese instante y el estado del instante anterior.

Finalmente, se tiene una capa lineal que transforma el estado en el último instante de tiempo a un vector cuyo tamaño es igual a la cantidad de tipos de electrodomésticos, de forma de representar probabilidades de pertenencia a cada tipo.

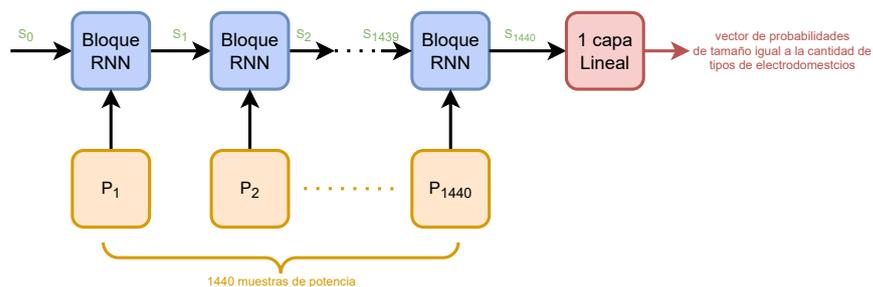


Figura A.3: Arquitectura RNN para la clasificación de electrodomésticos. Varios bloques RNN seguidos de una última capa lineal.

El código Python correspondiente es:

```
from tsai.models.RNN import RNN
model = RNN(c_in=1, c_out=cant_elecs),
```

Apéndice A. Arquitecturas de redes neuronales

Las RNN son una opción adecuada para procesar series temporales debido a su capacidad de recordar información pasada. Sin embargo, uno de los problemas ampliamente conocidos que presentan las RNN es el *vanishing gradient* [128], que ocurre cuando se alimenta a la arquitectura con secuencias largas, produciendo que durante el *back propagation* el gradiente se desvanezca, por lo que la red no aprende.

A.1.3. LSTM

La arquitectura LSTM [129] sigue los mismos principios que la RNN, buscando solucionar el problema de *vanishing gradient*. Para resolver el problema se modifica las relaciones entre s_t y s_{t-1} , introduciendo un estado adicional conocido como *cell state* c_t . Las ecuaciones que modelan un bloque LSTM son:

$$f_t = \sigma(W_f \cdot \text{concat}[s_{t-1}, P_t] + b_f)$$

$$i_t = \sigma(W_i \cdot \text{concat}[s_{t-1}, P_t] + b_i)$$

$$D_t = \sigma(W_D \cdot \text{concat}[s_{t-1}, P_t] + b_D)$$

$$C_t = f_t \circ C_{t-1} + i_t \circ D_t$$

$$o_t = \sigma(W_o \cdot \text{concat}[s_{t-1}, P_t] + b_o)$$

$$h_t = o_t \circ \tanh(C_t)$$

En la Figura A.4 se visualizan las relaciones de las ecuaciones anteriores. Mientras que en la Figura A.5 se presenta como se combina el bloque LSTM a lo largo del tiempo para clasificar series temporales. Notar que es completamente análogo al caso de las RNN.

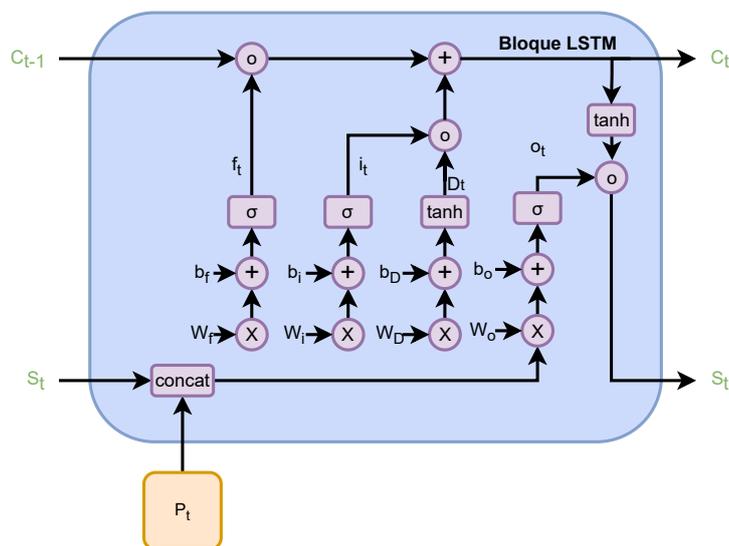


Figura A.4: Esquema de un bloque de una red neuronal recurrente de tipo LSTM. Donde s_t es el estado y P_t la entrada

El fragmento de código a utilizar para obtener el modelo en Python es:

A.1. Arquitecturas de identificación

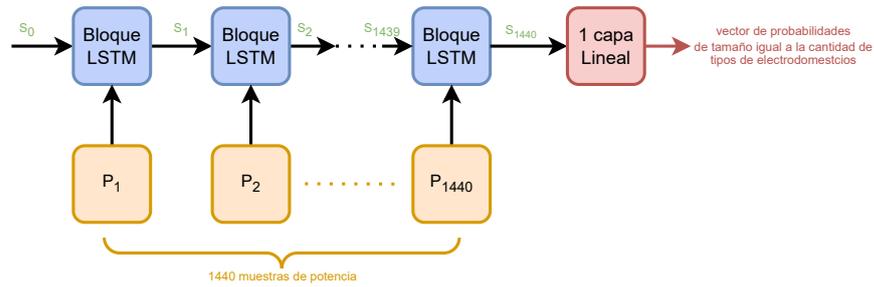


Figura A.5: Arquitectura LSTM para la clasificación de electrodomésticos. Varios bloques LSTM seguidos de una última capa lineal.

```
from tsai.models.LSTM import LSTM
model = LSTM(c_in=1, c_out=cant_elecs),
```

A.1.4. FCN

Las Fully Convolutional Networks (FCN) [117] son un tipo de red neuronal que emplean exclusivamente capas convolucionales (o filtros), a diferencia de las redes neuronales convencionales que combinan capas convolucionales con capas completamente conectadas. Las FCN resultan especialmente apropiadas para el procesamiento de series temporales, debido a que las capas convolucionales pueden analizar eficientemente la información temporal, al mismo tiempo que reducen la dimensionalidad de los datos.

La primera etapa de una FCN consiste en una capa convolucional encargada de identificar diversos patrones de características a partir de la serie temporal de entrada. Posteriormente, se aplican varias capas convolucionales adicionales con el fin de aprender patrones de características más complejos y sofisticados. Por último, se utiliza una capa de Global Average Pooling [130] que es utilizado como entrada para una capa de clasificación. La Figura A.6 representa esquemáticamente la arquitectura de FCN, en la que se omiten las activaciones y capas de normalización.

En TSAI, se pueden definir una FCN de la siguiente manera:

```
from tsai.models.FCN import FCN
model = FCN(c_in=1, c_out=cant_elecs),
```

El uso de convoluciones en series temporales presenta varios beneficios. En primer lugar, las convoluciones son capaces de procesar patrones complejos en las series temporales. Además, tienen la capacidad de reducir la dimensionalidad de los datos. En general, el uso de convoluciones en series temporales permite que la red neuronal aprenda representaciones más robustas y sofisticadas de las series temporales, lo que suele mejorar significativamente el rendimiento.

Apéndice A. Arquitecturas de redes neuronales

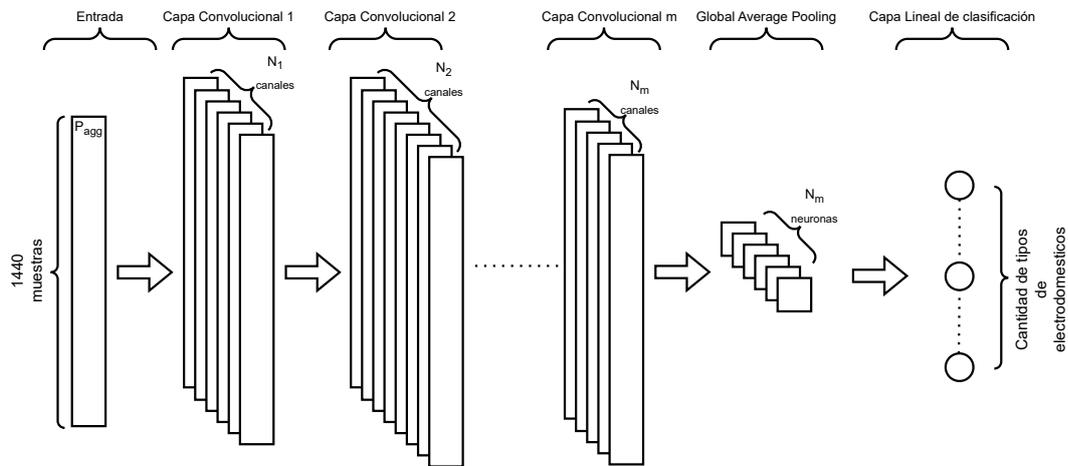


Figura A.6: Arquitectura FCN para la clasificación de electrodomésticos.

A.1.5. ResNet

Las redes neuronales residuales (ResNet) [114] son un tipo de red neuronal profunda que utiliza conexiones residuales para mejorar el flujo de información a través de la red. En contraste con las redes neuronales convencionales, donde cada capa procesa la información de forma secuencial y lineal, las ResNet utilizan un mecanismo que permite que la información fluya a través de la red de forma más directa.

Para esto, las ResNet modifica la arquitectura de la FCN, modificando cada una de las capas convolucionales por el llamado bloque ResNet. Este consiste en 3 convoluciones y una conexión residual. El incluir las conexiones residuales suele mejorar significativamente el rendimiento de los modelos de redes neuronales. La Figura A.7 muestra la composición de este bloque.

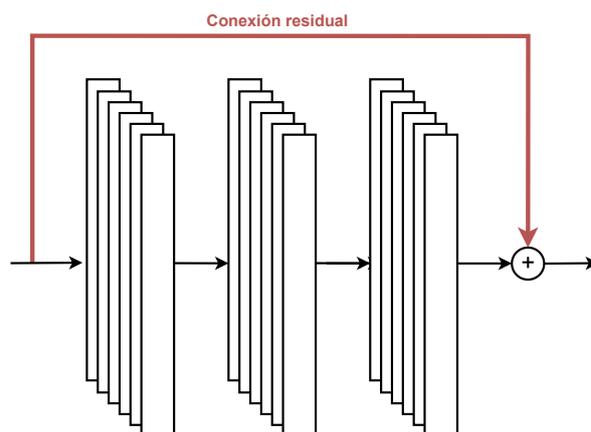


Figura A.7: Arquitectura ResNet para la clasificación de electrodomésticos.

En TSAI, se pueden definir ResNet para series temporales de la siguiente ma-

nera:

```
from tsai.models.ResNet import ResNet
model = ResNet(c_in=1, c_out=cant_elecs)
```

A.1.6. InceptionTime

InceptionTime [115] es una arquitectura de red neuronal convolucional diseñada específicamente para el análisis y procesamiento de series temporales. Esta arquitectura fue propuesta originalmente para el procesamiento de imágenes. La modificación sigue la misma idea que el de ResNet, que consiste en proponer un nuevo bloque llamado Inception.

El bloque Inception emplea diversas operaciones de convolución con distintos tamaños de filtro de manera paralela para procesar la entrada. Posteriormente, concatena las salidas de estas operaciones convolucionales para generar una única salida. La Figura A.8 ilustra el bloque Inception original propuesto para redes neuronales sobre imágenes, el cual utiliza convoluciones bidimensionales. Esto no representa una pérdida de generalidad, ya que para el caso unidimensional, el bloque Inception se adapta de manera análoga, empleando convoluciones unidimensionales en su lugar.

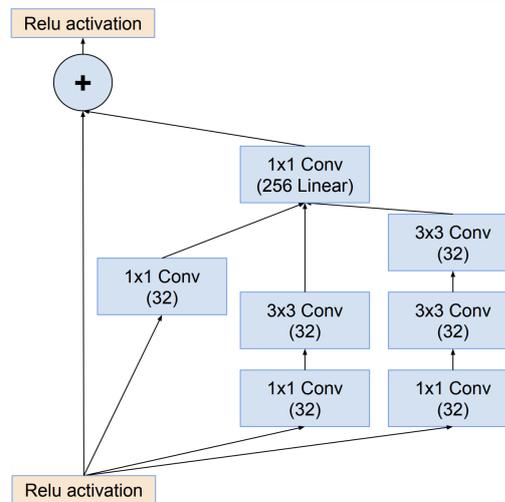


Figura A.8: Bloque Inception. Imagen extraída de [131].

La implementación de módulos Inception en InceptionTime ofrece varios beneficios. En primer lugar, permite que la red procese información en distintas escalas y resoluciones, mejorando así su habilidad para capturar patrones en series temporales con variadas longitudes y frecuencias.

En la biblioteca TSAI, es posible definir modelos de InceptionTime para clasificación utilizando el siguiente código:

```
from tsai.models.InceptionTime import InceptionTime
model = InceptionTime(c_in=1, c_out=cant_elecs)
```

Apéndice A. Arquitecturas de redes neuronales

A.1.7. XCM

La arquitectura XCM (eXplainable Convolutional neural network for MTS classification) es una red neuronal convolucional compacta, diseñada para la clasificación de series temporales multivariadas con un enfoque en la explicabilidad.

XCM facilita la implementación de un método de explicabilidad específico conocido como Gradient-weighted Class Activation Mapping (Grad-CAM). Para los propósitos de este documento y considerando que una explicación detallada de la arquitectura y el método Grad-CAM está fuera del alcance de este documento, se puede asumir que XCM utiliza múltiples capas convolucionales de forma ingeniosa, logrando un alto rendimiento y una notable capacidad de explicabilidad en tareas de clasificación.

Se puede encontrar el código fuente de XCM, así como diagramas de la arquitectura en detalle, en el siguiente enlace: <https://github.com/XAISeries/XCM>.

Para utilizar la arquitectura XCM en Python mediante la biblioteca TSAI, se puede emplear el siguiente código:

```
from tsai.models.XCM import XCM
model = XCM(
    c_in=1,
    c_out=cant_elects,
    seq_len=1440,
)
```

A.2. Arquitecturas de desagregación

En esta sección, se exponen las arquitecturas de redes neuronales utilizadas para llevar a cabo la tarea de desagregación de consumo. Las entradas a estos modelos son la serie de potencia activa y reactiva agregada, muestreada a intervalos de 15 minutos a lo largo de un día, dando lugar a dos canales con 96 muestras. La salida también corresponde a una serie temporal con tasas de muestreo de 1 minuto o 15 minutos, es decir, 1440 muestras o 96 muestras, respectivamente. A los efectos de este análisis, se explican los modelos con salidas a tasa de 15 minutos, pero cabe destacar que obtener modelos a tasa de 1 minuto implica realizar modificaciones menores en los códigos presentados, sin ningún cambio conceptual.

A.2.1. Denoising Autoencoder (DAE)

Este es uno de los modelos fundacionales de NILM, propuesto en [42]. Esta arquitectura hace uso de la idea de la arquitectura de Autoencoder (AE), las cuales se basan en reconstruir a la salida la señal a la entrada. La clave de la misma es comprimir la entrada con un bloque de *Encoder* a un espacio de menor dimensión y luego a descomprimirla con un bloque de *Decoder*, la Figura A.9 ilustra lo anterior. La intuición detrás de esta idea consiste en que el Encoder se encarga de descartar toda información que no es útil para reconstruir la señal, en otras palabras, implementa una reducción de dimensionalidad como podría hacer PCA.

A.2. Arquitecturas de desagregación

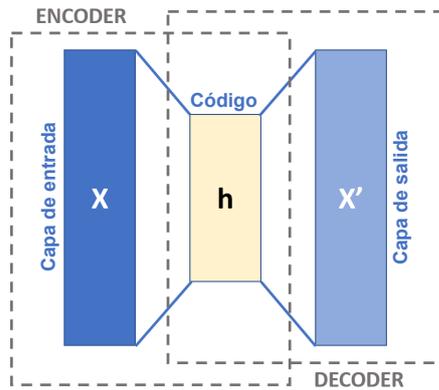


Figura A.9: Esquema de una red neuronal de tipo Autoencoder, compuesta por un bloque de Encoder y un bloque de Decoder.

Los *Autoencoders* pueden ser utilizados como *Denoising Autoencoder*, debido a que en el proceso de compresión de información son capaces de eliminar el ruido y reconstruir la señal sin este. En el contexto de NILM, J. Kelly, quien propuso esta arquitectura en [42], justifica que se puede ver a la serie de potencias agregadas como ruido sumando a la serie del electrodoméstico de interés.

La arquitectura propuesta en [42] consiste en varias capas convolucionales y lineales. En concreto, la definición del modelo en código se puede ver en https://github.com/camilomarinonilm_disaggregation_nets/blob/main/nilm_disaggregation_nets/neural_nilm.py. El código para utilizar el modelo es el siguiente:

```
from nilm_disaggregation_nets import NeuralNilmDAE
model = NeuralNilmDAE(
    sequence_length=96,
    in_channels=2, # active power and reactive power
    out_channels=1 # only active power
)
```

A.2.2. Fully Convolutional Denoising Autoencoder

Esta arquitectura no ha sido propuesta en trabajos previos de NILM, pero se fundamenta en la combinación de la arquitectura DAE con una FCN. Consiste en una arquitectura con un cuello de botella, igual que en el DAE, pero que emplea exclusivamente capas convolucionales.

La definición detallada del modelo, capa por capa, se encuentra disponible en https://github.com/camilomarinonilm_disaggregation_nets/blob/main/nilm_disaggregation_nets/others.py. Para utilizar el modelo, el código es el siguiente:

```
from nilm_disaggregation_nets import FullyConvolutionalDAE
model = FullyConvolutionalDAE(
    in_channels=2, # active power and reactive power
    out_channels=1 # only active power
)
```

)

A.2.3. BiLSTM

La BiLSTM es también uno de los modelos fundacionales de NILM, propuesto en [42]. Consiste en redes LSTM bidireccionales, cuyas entradas y salidas son series temporales.

La limitación de una LSTM convencional radica en que tiende a dar mayor importancia a las entradas cercanas al final de la secuencia que a aquellas entradas cercanas al inicio ($t = 0$). Para abordar este problema, se utilizan LSTM bidireccionales, también conocidas como BiLSTM. Esta arquitectura consiste en apilar dos LSTM: una que se alimenta con la secuencia de entrada en sentido directo y otra en sentido inverso. Posteriormente, se combinan los estados finales de ambas LSTM mediante una capa lineal y se genera una nueva serie temporal de salida. La Figura A.10 ilustra la arquitectura de una BiLSTM para NILM.

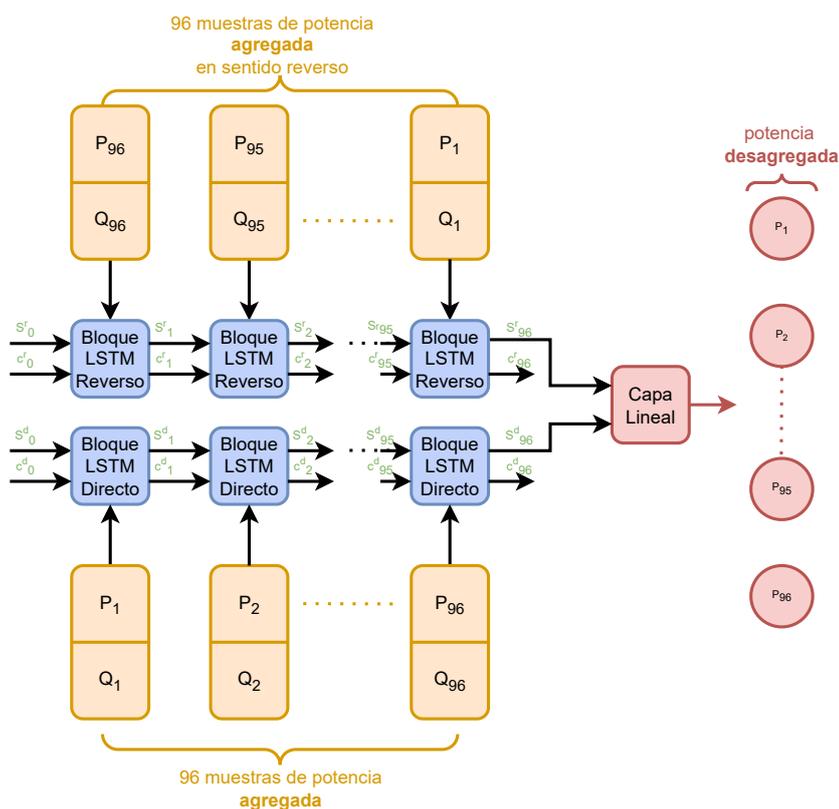


Figura A.10: Arquitectura BiLSTM para desagregación de consumo. Dos LSTM apiladas seguidas de una última capa lineal.

La implementación de la red se encuentra disponible en https://github.com/amilomarinonilm_disaggregation_nets/blob/main/nilm_disaggregation_nets/neut_al_nilm.py. Para utilizar la red BiLSTM, el código es el siguiente:

A.2. Arquitecturas de desagregación

```
from nilm_disaggregation_nets import NeuralNilmBiLSTM
model = NeuralNilmBiLSTM(
    sequence_length=96,
    in_channels=2, # active power and reactive power
    out_channels=1 # only active power
)
```

A.2.4. Seq2Seq

La arquitectura secuencia a secuencia (Seq2Seq) se ha empleado en varios trabajos [56, 132] de NILM, aunque no presenta innovaciones particulares. Consiste en cinco capas convolucionales seguidas de una capa lineal final. La arquitectura sigue un esquema muy similar a la FCN de clasificación, como se muestra en la Figura A.6, pero sin la capa de Global Average Pooling y con dos canales de entrada en lugar de uno.

La implementación específica de esta arquitectura se puede encontrar en https://github.com/camilomarino/nilm_disaggregation_nets/blob/main/nilm_disaggregation_nets/seq_to.py. Para utilizarla, el código es el siguiente:

```
from nilm_disaggregation_nets import SeqToSeq
model = SeqToSeq(
    input_length=96,
    in_channels=2, # active power and reactive power
    out_channels=1 # only active power
)
```

A.2.5. ResNet

La arquitectura utilizada en este caso es una variante de la ResNet de clasificación presentada en la Sección A.1.5, con modificaciones para realizar la tarea de desagregación. La diferencia principal radica en que se elimina la capa de Global Average Pooling y se ajusta la capa lineal final.

Para implementar esta variante de ResNet, se utiliza la biblioteca TSAI como punto de partida y se ajusta la arquitectura según las necesidades específicas del problema de desagregación de NILM. Al hacerlo, se crea una red que puede manejar entradas de múltiples canales, como potencia activa y potencia reactiva, y producir salidas adecuadas para la tarea de desagregación. A continuación, se muestra la definición del modelo con las modificaciones pertinentes, así como el código para invocar el modelo:

```
from torch import nn
from tsai.models.ResNet import ResNet as ResNetTSAI
class ResNet(nn.Module):
    def __init__(self, in_channels, out_channels=1) -> None:
        """
        A fully convolutional resnet adjusted from
```

Apéndice A. Arquitecturas de redes neuronales

```
implementation of tsai library.
"""
super (). __init__ ()
self.resnet_tsai = ResNetTSAI(in_channels , 1)
self.resnet_tsai.gap, self.resnet_tsai.squeeze = [
    nn.Identity ()
] * 2
self.resnet_tsai.fc = nn.Conv1d(
    128, out_channels , kernel_size=3, padding=1
)

def forward(self , x: Tensor) -> Tensor:
    return self.resnet_tsai(x)
```

```
model = ResNet(in_channels=2, out_channels=1)
```

A.2.6. InceptionTime

La versión de InceptionTime utilizada para la desagregación es una adaptación de la arquitectura de InceptionTime para clasificación, presentada en la Sección A.1.6. Al igual que en el caso de la ResNet, sobre InceptionTime se aplican modificaciones similares para adaptarla al problema de desagregación. Estas modificaciones incluyen ajustar la arquitectura para trabajar con series temporales y eliminar la capa de Global Average Pooling. El código correspondiente es:

```
from torch import nn
from tsai.models.InceptionTime import (
    InceptionTimePlus as InceptionTimeTSAI,
)
class InceptionTime(nn.Module):
    def __init__(self , in_channels , out_channels=1) -> None:
        """
        A fully convolutional InceptionTime adjusted
        from implementation of tsai library.
        """
        super (). __init__ ()
        self.inception_time_tsai = InceptionTimeTSAI(
            in_channels , 1
        )
        self.inception_time_tsai.gap = nn.Identity ()
        self.inception_time_tsai.fc = nn.Conv1d(
            128, out_channels , kernel_size=3, padding=1
        )

    def forward(self , x: Tensor) -> Tensor:
        return self.inception_time_tsai(x)
```

A.2. Arquitecturas de desagregación

```
model = InceptionTime(in_channels=2, out_channels=1)
```

La implementación de esta variante de InceptionTime aprovecha las ventajas de la arquitectura original, como la capacidad de procesar información en diferentes escalas y resoluciones.

A.2.7. Mean

El modelo Mean es el utilizado como línea base (baseline) para la desagregación en NILM. Este modelo simple calcula el valor medio de la potencia del electrodoméstico que se desea desagregar a lo largo del conjunto de entrenamiento. Posteriormente, establece una salida constante igual a dicho valor medio, independientemente de la entrada que reciba.

Aunque el modelo Media es básico y no tiene en cuenta la dinámica temporal ni las características particulares de cada dispositivo, proporciona un punto de referencia importante para evaluar el rendimiento de los modelos de desagregación más avanzados. Al comparar los resultados de otros modelos con los de este modelo básico, es posible determinar si las técnicas más complejas logran mejorar.

Apéndice B

Enfoques alternativos de desagregación

B.1. Inclusión del clasificador en la función de pérdida

En esta sección se presenta un enfoque sobre cómo se intentó combinar el clasificador y el desagregador. El objetivo era integrar ambos para que, al trabajar en conjunto, el desempeño del desagregador mejorara.

La idea consistió en modificar la función de pérdida de entrenamiento de las redes neuronales de desagregación, agregando un término de error que representara qué tan parecida era la señal desagregada al electrodoméstico de interés. En otras palabras, clasificar la señal desagregada y penalizar si la clasificación no corresponde al electrodoméstico de interés.

La función de pérdida específica utilizada fue:

$$\text{loss} = \alpha \cdot \frac{1}{N} \sum_{t=0}^{N-1} (f^{-1}(P_{agg}(t), R_{agg}(t)) - P_{elec}(t))^2 + \beta \cdot \text{CE}(\text{clasifier}(f^{-1}(P_{agg}(t), R_{agg}(t))), \hat{y}_{elec}).$$

La Figura B.1 ilustra de forma esquemática la función de pérdida propuesta.

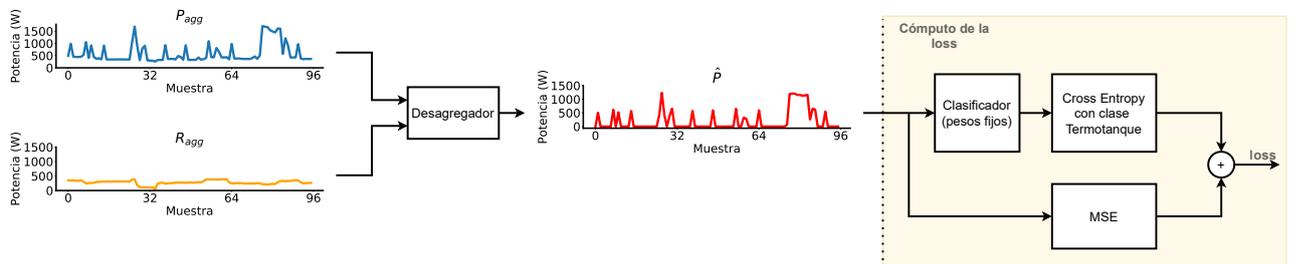


Figura B.1: Esquema de desagregación incluyendo el clasificador en el cálculo de la función de pérdida.

Este enfoque fue investigado pero no se logró mejorar los resultados, por lo que

Apéndice B. Enfoques alternativos de desagregación

se optó por descartarlo en favor de uno más sencillo. No obstante, el mismo y sus variantes podrían ser explorados en trabajos futuros.

B.2. Inclusión de una función de pérdida por estados

En el Capítulo 5, se mostró que el modelo desagregador experimentó dificultades para desagregar la salida cuando estaba en un periodo de una muestra por minuto. En particular, las recuperaciones del termotanque, que consisten en pulsos de corta duración, no fueron desagregadas correctamente.

Debido a lo anterior, se exploró la posibilidad de modificar la función de pérdida con el objetivo de mejorar el desempeño del modelo en las recuperaciones. La idea consiste en asignar más peso a los segmentos en los que el termotanque se encuentra encendido por cortos periodos de tiempo dentro de la función de pérdida.

Por lo tanto, la modificación implicó segmentar los distintos intervalos en estado ON del termotanque y calcular su longitud. Luego, el error cuadrático medio de cada segmento se pondera según el inverso de la longitud calculada en el paso anterior.

La fórmula de la función de pérdida implementada fue la siguiente:

$$\text{loss} = \frac{1}{L} \sum_{s \in S} \sum_{t \in s} (f^{-1}(P_{agg}(t), R_{agg}(t)) - P_{elec}(t))^2,$$

donde L es la longitud total de la serie temporal y S es el conjunto de segmentos disjuntos de la serie temporal.

Este enfoque fue investigado logrando resultados comparables, aunque demandando un incremento en la capacidad computacional para procesar la función de pérdida. Sin embargo, en futuras investigaciones podrían explorarse variantes del mismo.

Apéndice C

NMF aplicado a NILM

En este apéndice, se incluye el reporte de los resultados experimentales y conclusiones obtenidas al aplicar métodos de desagregación NILM con un abordaje basado en Negative Matrix Factorization (NMF). Los experimentos se reportaron sobre la base pública AMPds, cuyos datos están dentro de la categoría de baja frecuencia. El reporte fue realizado en marco del proyecto de fin de curso de Teoría y Algoritmia de Optimización.

C.1. Modelado del problema

C.1.1. Enfoque básico

El enfoque más básico es modelar el problema como uno de mínimos cuadrados lineales.

$$\min_a \|x - Da\|_2^2 \quad (\text{C.1})$$

Donde \mathbf{x} es un vector que contiene la señal agregada. Se considera que $\mathbf{x} \in R^m$. Donde \mathbf{D} es llamada matriz de firmas o diccionario y tiene en cada columna un \mathbf{d} . Es decir, es una matriz en que cada columna es una ventana de consumo de un electrodoméstico. Se considera $\mathbf{D} \in R^{m \times T}$.

$$\mathbf{D} = \begin{pmatrix} | & | & \dots & | \\ d_1 & d_2 & & d_T \\ | & | & & | \end{pmatrix}$$

Mientras que \mathbf{a} , que es la variable de optimización, representa cuanto debería aportar cada \mathbf{d}_i para reconstruir la señal agregada.

Por lo tanto la Ecuación (C.1) pretende que cada consumo agregado se pueda descomponer como la suma ponderada de firmas de electrodomésticos.

Este enfoque presenta el gran problema de que algún elemento de \mathbf{a} sea negativo. Esto en la práctica implicaría que una firma aporte potencia negativa, por lo cual no es físicamente posible y se pretende evitar en el modelado.

Apéndice C. NMF aplicado a NILM

C.1.2. Enfoque con restricción

Por lo que se explicó, una restricción útil es forzar que \mathbf{a} sea no negativo. Es decir, que el problema de optimización sea:

$$\boxed{\min_{a \geq 0} \|x - Da\|_2^2} \quad (\text{C.2})$$

Este modelo permite una resolución más real, ya que la señal agregada es una suma ponderada positiva de firmas.

El inconveniente que presenta este enfoque es que no se limita cuanto puede aportar cada electrodoméstico a la señal. Esto es un problema porque \mathbf{D} está formado por más de una firma de cada electrodoméstico, generando que la señal pueda ser reconstruida exclusivamente por varias firmas de unos pocos electrodomésticos. Es decir, se podría reconstruir la señal agregada por medio únicamente de la suma de lámparas, ya que estas a priori pueden aportar la potencia/corriente que sea necesaria.

Para resolver este inconveniente, es posible añadir diversas regularizaciones sobre \mathbf{a} . En las siguientes secciones se abordan algunas de ellas.

C.1.3. Enfoque con regularización L-1

Consiste en añadir un término de penalización con la norma L-1 de \mathbf{a} .

$$\min_{a \geq 0} \|x - Da\|_2^2 + \beta \|a\|_1 \quad (\text{C.3})$$

La intuición detrás de esta normalización, es generar que \mathbf{a} sea dispersa (varios elementos en 0). Esto evita que se reconstruya la señal por medio de muchas firmas y hace que no todas aporten.

C.1.4. Enfoque con regularización L-2

Igual que con L-1, pero con penalización L2 sobre \mathbf{a} .

$$\min_{a \geq 0} \|x - Da\|_2^2 + \beta \|a\|_2 \quad (\text{C.4})$$

La idea detrás de esta regularización es que no haya elementos de \mathbf{a} demasiado elevados. Esta regularización hace que no se reconstruya la señal exclusivamente a partir de grandes aportes de algunas firmas.

C.1.5. Enfoque con regularización Elastic Net

Combina la regularización L-1 y L-2 agregando ambos términos en el problema de optimización.

$$\min_{a \geq 0} \|x - Da\|_2^2 + \beta_1 \|a\|_1 + \beta_2 \|a\|_2 \quad (\text{C.5})$$

C.1.6. Enfoque con regularización Sum-to-k

Un enfoque más novedoso y específico para este problema es el que se propone en [133]. Para entenderlo es necesario recordar que \mathbf{D} esta formado por T firmas de k electrodomésticos distintos, teniendo de esta forma $\frac{T}{k}$ firmas por cada aparato si es que el problema esta balanceado.

La idea de sum-to-k (**S2K**) es que la suma por grupo de electrodomésticos sea 1 o cercano a este valor. Cada grupo de firmas está compuesto por las firmas correspondientes al mismo electrodoméstico.

Esto elimina por completo el problema que un aparato aporte más potencia de la que suele aportar. Además exige que todos los electrodomésticos aporten alguna de sus firmas al consumo agregado, potencialmente 0 si alguna de sus firmas es nula.

En la práctica existen dos variantes de implementación de S2K. La primera de ellas, la cual es la que se propone en el artículo de referencia [133], añade S2K mediante un término que penaliza cuando la suma por grupo es distinta de 1. La formulación es la siguiente:

$$\min_{a \geq 0} \|x - Da\|_2^2 + \beta \|u - Qa\|_2^2$$

Con $u \in R^k$ un vector completo de 1 y $Q \in R^{k \times T}$ una matriz. A modo de ejemplo si se tienen 3 grupos de electrodomésticos, cada uno con 3, 1 y 2 firmas respectivamente, la matriz u es de tamaño 3 y Q es 3x6; y sus componentes son:

$$u = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}, Q = \begin{pmatrix} 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 1 \end{pmatrix}$$

De esta forma se tiene que el costo correspondiente al segundo termino será 0 solo en el caso de que se cumpla exactamente la S2K.

El problema se puede reescribir para que tenga la misma forma que en la ecuación (C.2).

$$\min_{a \geq 0} \left\| \begin{bmatrix} x \\ \beta u \end{bmatrix} - \begin{bmatrix} D \\ \beta Q \end{bmatrix} a \right\|_2^2 \quad (\text{C.6})$$

Sin embargo este problema tiene la complicación de la elección del β , el cual puede ser difícil de escoger y dado los largos tiempos de entrenamiento, el realizar una validación cruzada en busca del β óptimo es costoso.

Por lo anterior, se propone una variante que consiste en añadir S2K como una restricción, que impone que la suma por grupo sea 1. El problema asociado es:

$$\begin{array}{l} \min_{a \geq 0} \|x - Da\|_2^2 \\ \text{subject to } \sum_{i \in \text{Group}} a_i = 1 \quad \forall \text{Group} \end{array} \quad (\text{C.7})$$

C.1.7. Generalización

Todas las variantes planteadas pueden ser generalizadas a un problema que desagrega varios días en simultáneo. Esto se logra cambiando el vector \mathbf{x} por una matriz \mathbf{X} , que en cada columna posea un \mathbf{x} . Lo mismo ocurre con \mathbf{a} , que puede ser sustituido por una matriz \mathbf{A} .

C.2. Supuestos y Limitaciones

Los modelados propuestos se basan en que el consumo de un día puede ser desagregado mediante la suma de consumos de electrodomésticos en otro día. El gran problema que esto presenta es que para asignar que un electrodoméstico tenga determinado patrón de consumo, ya debe existir un patrón de consumo similar en la matriz \mathbf{D} .

A modo de ejemplo, si se quiere desagregar un consumo \mathbf{x} en el que una televisión fue encendida a las 4:00 AM y estuvo prendida por 2 horas, la única forma de conseguirlo es que exista en \mathbf{D} una firma de una TV en ese horario y con duración similar.

Por lo tanto, se supone que se cuenta con la suficiente cantidad de firmas \mathbf{d} , lo que es equivalente a tener una base de datos adquirida durante un largo período de tiempo. Este supuesto es necesario para capturar todos los patrones de consumo de cada electrodoméstico, estos refieren al modo de uso, tiempo que estuvo encendido y momento del día.

C.3. Métodos de Optimización

Lo primero a destacar es que todos los problemas planteados en la sección anterior son convexos. Esto es porque la función a optimizar es convexa (se corresponde con la de mínimos cuadrados), mientras que las restricciones de desigualdad e igualdad son lineales.

En este trabajo se resolvió el enfoque básico con restricción (Ecuación (C.2)) y las dos variantes de S2K (Ecuación (C.6) y (C.7)). A continuación, se muestran dos métodos que permiten la resolución del problema.

Explorando como resolver el problema, se utilizó *CVXPY* [134]. Dado el gran tamaño de las matrices utilizadas y los métodos genéricos que implementa *CVXPY*, no fue posible resolver el problema por este medio en un tiempo razonable.

C.3.1. NNLS

Tanto la ecuación (C.2) como (C.6) tienen la misma forma, por lo cual se puede aplicar el mismo mecanismo de optimización. Existe para estos casos el algoritmo NNLS [135] de resolución **exacta**. En el Algoritmo 2 se presentan los pasos que propone NNLS.

A modo de resumen, este es un algoritmo iterativo que posee un conjunto de variables activas y no activas que se van actualizando en cada paso. Para esto en

Algoritmo 2 NNLS.

Algoritmo extraído de [136] y [137], donde también se puede obtener una mayor intuición de cada uno de los pasos y porque este funciona.

A. Inicialización

- A1. $P \leftarrow \emptyset$
- A2. $R \leftarrow \{1, 2, \dots, M\}$
- A3. $\mathbf{a} \leftarrow \mathbf{0}$
- A4. $\mathbf{w} \leftarrow \mathbf{D}^T(\mathbf{x} - \mathbf{D}\mathbf{a})$

B. Loop Principal

- B1. Continuar si: $R \neq \emptyset \wedge \left[\max_{n \in R}(w_n) > \text{tolerancia} \right]$
- B2. $m \leftarrow \operatorname{argmax}_{n \in R}(w_n)$
- B3. Incluir el índice m en P y eliminar este de R
- B4. $\mathbf{s}^P \leftarrow \left[(\mathbf{D}^P)^T \mathbf{D}^P \right]^{-1} (\mathbf{D}^P)^T \mathbf{x}$

B. Loop interno

- C1. Continuar si $\min(\mathbf{s}^P) \leq 0$
 - C2. $\alpha \leftarrow -\min_{n \in P} \frac{a_n}{a_n - s_n}$
 - C3. $\mathbf{a} \leftarrow \mathbf{a} + \alpha(\mathbf{s} - \mathbf{a})$
 - C4. Actualizar R y P
 - C5. $\mathbf{s}^P \leftarrow \left[(\mathbf{D}^P)^T \mathbf{D}^P \right]^{-1} (\mathbf{D}^P)^T \mathbf{x}$
 - C6. $\mathbf{s}^R \leftarrow \mathbf{0}$
- Ir a B5*

- B5. $\mathbf{a} \leftarrow \mathbf{s}$
 - B6. $\mathbf{w} \leftarrow \mathbf{D}^T(\mathbf{x} - \mathbf{D}\mathbf{a})$
- Ir a B1*
-

Apéndice C. NMF aplicado a NILM

cada paso resuelve el problema de mínimos cuadrados solo con las restricciones no activas y verifica que el gradiente respecto a restricciones activas sea negativo. Por más detalle se sugiere ir a las referencias en las que se encuentra muy bien explicado.

Este algoritmo fue implementado por completo en *Python*. Esta implementación se encuentra disponible en el archivo *nmls.py*.

El problema que presenta NNLS es que no es eficiente, en cada paso se debe resolver un problema de mínimos cuadrados, lo que implica una inversión matricial. Esto lleva a que sea un algoritmo que no escala a un problema con matrices grandes. De todas formas, el implementarlo sirvió como primera aproximación a la resolución del problema. Además, fue útil para luego utilizarlo como referencia en la etapa de desarrollo de métodos aproximados que se presentaran a continuación.

C.3.2. PGD

Con el fin de tener un algoritmo que escale, se propone utilizar *Projected Gradient Descent*. Este enfoque nos permite resolver cualquiera de los tres problemas propuestos, a diferencia de NNLS que no sirve para resolver un problema cuya forma es de la Ecuación (C.7).

De forma general, PGD alterna un paso de gradiente con la proyección a la región factible. Considerando que la función que se quiere minimizar es $\min_{a \in C} f(a)$, un pseudocódigo de PGD se puede observar en el Algoritmo 3.

Algoritmo 3 Projected Gradient Descent Algorithm

P_C es la proyección al conjunto C

```
 $\alpha \leftarrow \frac{1}{\|D^T D\|_F^2}$ 
 $a \leftarrow a_0$ 
while not Stop Condition do
  |  $a \leftarrow P_C(a - \alpha \nabla f(a))$ 
end
```

En el caso particular de interés, se tiene que el gradiente de la función objetivo es $\nabla f(a) = 2a^T(Da - x)$.

Mientras que la proyección (P_C) depende del caso que tratemos. Si se desea proyectar a los al conjunto $C_1 = \{a \in R^T / a > 0\}$ alcanza con llevar a 0 todas aquellas componentes que sea menores a 0.

En cambio para proyectar a la restricción de S2K (Ecuación (C.7)), es un poco más complejo. En este caso se debe proyectar a dos conjuntos, en primer lugar a C_1 y luego a $C_2 = \left\{ a / \sum_{i \in \text{Group}} a_i = 1 \forall \text{Group} \right\}$. Para proyectar a C_2 lo que se hace es dividir cada elemento de a por la suma de los elementos de su grupo.

Este algoritmo fue implementado por completo en *Python* y hace uso de la GPU para acelerar el entrenamiento mediante el framework *Pytorch*. El código correspondiente se encuentra en *pgd.py*.

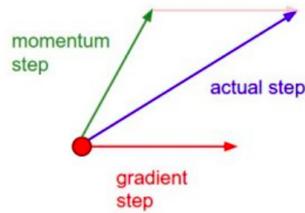


Figura C.1: Nesterov Momentum

Con PGD se logra que mejorar sustancialmente el tiempo respecto a NNLS. De todas formas, con el objetivo de mejorar aún más la velocidad de convergencia, en la siguiente sección se proponen una mejora llamada A-PGD.

C.3.3. A-PGD

Accelerated Projected Gradient Descent (A-PGD) es una variación del método PGD que pretende mejorar la velocidad de convergencia.

Para lograr esto, lo que hace A-PGD es agregar momentum (o inercia) a la actualización del gradiente. Esto implica que en cada paso se actualice el valor de \mathbf{a} con una componente del gradiente actual y otro del momentum, como se ilustra en la Figura C.1¹.

El pseudocódigo de APG se puede ver en el Algoritmo 4.

Algoritmo 4 Accelerated Projected Gradient Descent Algorithm

α es el paso del algoritmo

P_C es la proyección al conjunto C

μ parámetro de momentum del problema

$a \leftarrow a_0$

while not Stop Condition do

$v \leftarrow \mu v - \alpha \nabla f(a)$

$a \leftarrow P_C(a + v)$

end

La implementación consistió en una variante de Nesterov Momentum, que utiliza ADAM. El código se implementó en *Python* y se encuentra en el archivo *apgd.py*.

C.3.4. Comparativa

Con fines comparativos se plantea el problema de la ecuación (C.2) con tamaños de las matrices pequeños.

¹Imagen extraída de: <https://cs231n.github.io/neural-networks-3/>

Apéndice C. NMF aplicado a NILM

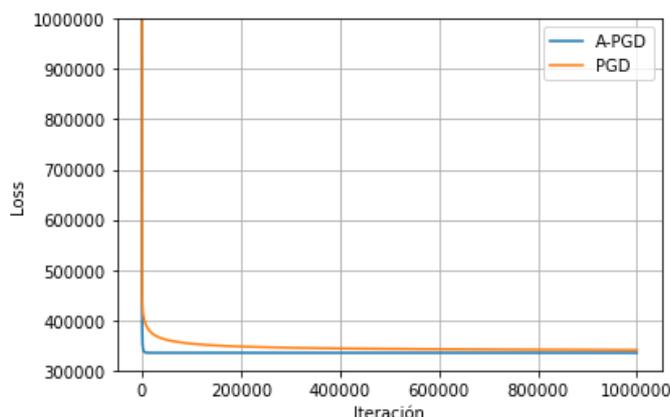


Figura C.2: Comparativa de la evolución de la loss entre PGD y A-PGD con matrices pequeñas.

En la Figura C.2 se muestra la curva comparativa de la evolución de la loss en PGD y A-PGD. Ambos métodos llegan a la solución óptima dada por NNLS. Sin embargo, como se observa en la gráfica A-PGD llega en mucho menos iteraciones que PGD. Por esto en la sección de experimentos, se decidió utilizar **A-PGD** como método de resolución.

C.4. Experimentos

C.4.1. Base de datos: AMPds

AMPds [138] es un dataset público de consumo eléctrico recolectado en Canadá. Cuenta con 2 años de **series corriente** eléctrica a una frecuencia de una muestra por minuto. De los 21 medidores, 20 de estos se encargaron de recolectar los consumos desagregados y el restante para adquirir la señal del tablero general.

Las 20 señales desagregadas con las que se cuenta son:

- Whole-House Meter
- North Bedroom
- Master and South Bedroom
- Basement Plugs and Lights
- Clothes Dryer
- Clothes Washer
- Dining Room Plugs
- Dishwasher
- Electronics Workbench

C.4. Experimentos

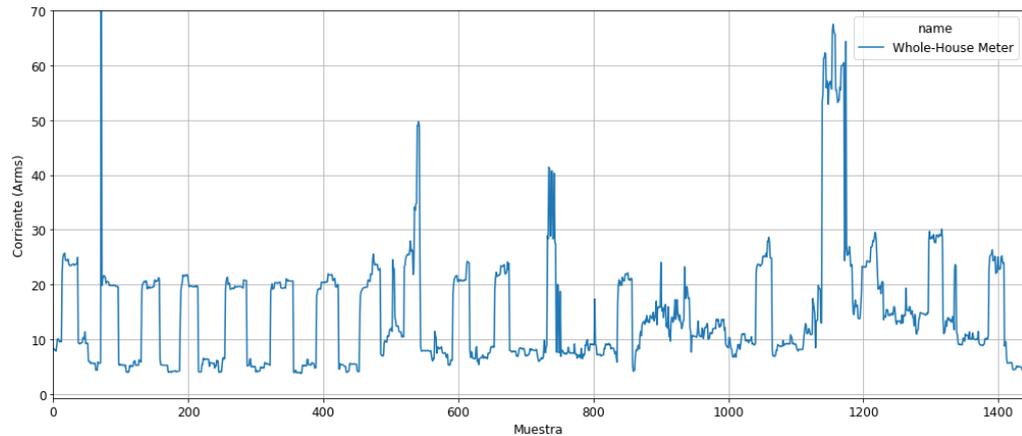


Figura C.3: Curva de corriente agregada correspondiente al primer día de consumo de la base AMPds.

- Security/Network Equipment
- Kitchen Fridge
- Forced Air Furnace: Fan and Thermostat
- Garage
- Heat Pump
- Instant Hot Water Unit
- Home Office
- Outside Plug
- Rental Suite
- Entertainment: TV, PVR, AMP
- Utility Room Plug
- Wall Oven

Notar que no todas las señales desagregadas corresponden a un único electrodoméstico. Por ejemplo, algunas corresponden a enchufes o habitaciones. Sin embargo esto no afecta al modelado, ya que pueden considerarse a estas señales como provenientes de un súper-electrodoméstico, cuya señal es la suma de las señales de un conjunto de electrodomésticos.

En la Figura C.3 se muestra una de las señales agregadas, mientras que en la Figura C.4 se observan las señales desagregadas.

Todo el preprocesamiento y post-procesamiento de los datos se realizó mediante el Toolkit de *Python* llamado *NILMTK* [139].

Apéndice C. NMF aplicado a NILM

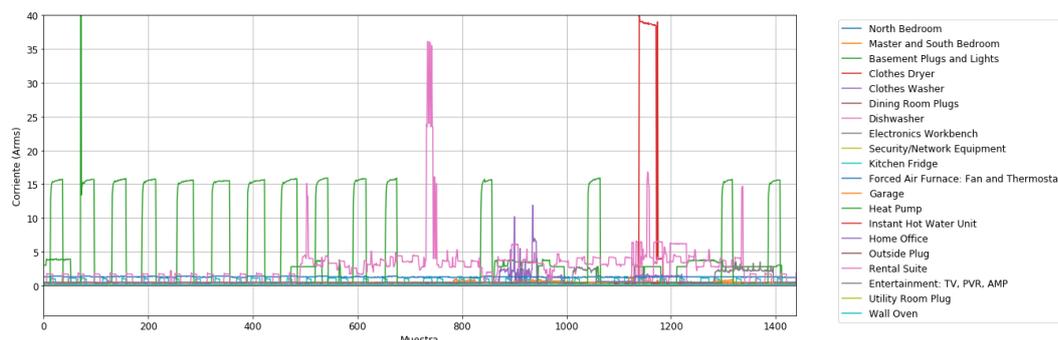


Figura C.4: Curva de corriente correspondiente a cada electrodoméstico del primer día de la base AMPds.

C.4.2. Métricas de desempeño

Se presentan dos métricas que son de interés para este problema de NILM.

C.4.2.1. Disaggregation Error

Corresponde al error medio muestra a muestra en corriente entre la señal real y la reconstruida.

$$DE = \sum_{i=1}^k \frac{1}{km} \|x_i - \hat{x}_i\|_1^2$$

En este trabajo solo se utiliza para la señal agregada. DE mide cuan bien se reconstruye la señal agregada y se debe notar que no aporta información sobre que tan bien se desagrega el consumo.

C.4.2.2. PCEC

Indica el porcentaje que ha sido asignado a cada electrodoméstico sobre el total de consumo estimado.

Esta es una métrica de desagregación y no aporta información de sí se reconstruye bien la señal agregada.

C.4.3. Resultados

Como ya se mencionó, se resuelven tres problemas mediante A-PGD.

Se realizó una división 80 %-20 % en los datos. Es decir, como se tenían exactamente 715 días de datos, 580 fueron utilizados como entrenamiento (en la matriz \mathbf{D}) y 135 fueron utilizados para evaluar (en el vector \mathbf{x}).

Se muestra la evolución de la loss, el DE y el PCEC. Más adelante, en la Sección C.4.4, se presentan algunos ejemplos de la señal agregada y desagregada estimada para cada uno de los tres problemas resueltos.

C.4. Experimentos

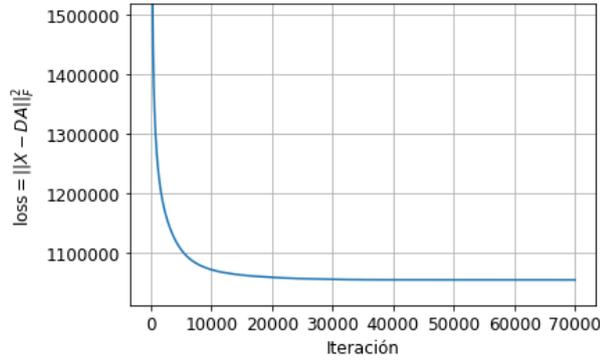
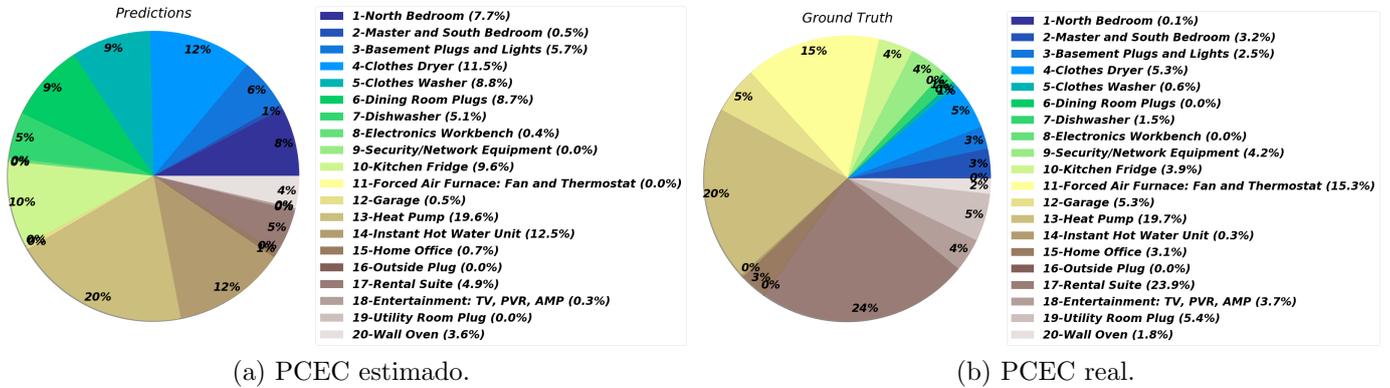


Figura C.5: Evolución de la loss al resolver $\min_{a \geq 0} \|x - Da\|_2^2$ mediante A-PGD.



(a) PCEC estimado.

(b) PCEC real.

Figura C.6: PCEC problema sin restricción.

C.4.3.1. Enfoque con restricción ($a > 0$)

Este es el enfoque en el que no se añade regularización, en la Figura C.5 se observa la evolución de la loss a lo largo de las iteraciones. Se aprecia que esta logra la convergencia, ya que se estabiliza.

El DE obtenido es de 1,31A, lo que representa que se ha reconstruido la señal con poco error.

A continuación, en la Figura C.6 se presenta la comparativa del PCEC estimado con el PCEC real. Se ve que estos difieren, por ejemplo se le estima 0% para *Forced Air Fournace*, siendo este uno de los que más consume en verdad.

Que se tenga un buen DE, pero mal PCEC se explica porque el algoritmo se concentra en reconstruir la señal lo más preciso que se pueda, sin tener en cuenta ninguna estructura específica del problema. Por esto fue que se propuso agregar S2K.

C.4.3.2. Regularización con S2K

En este caso, para resolver el problema, es necesario escoger el valor del parámetro β , para esto se usó una búsqueda en grilla. Se escogió $\beta = 10$, ya que este mejo-

Apéndice C. NMF aplicado a NILM

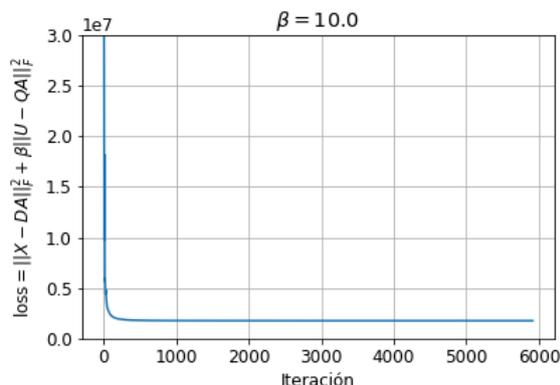
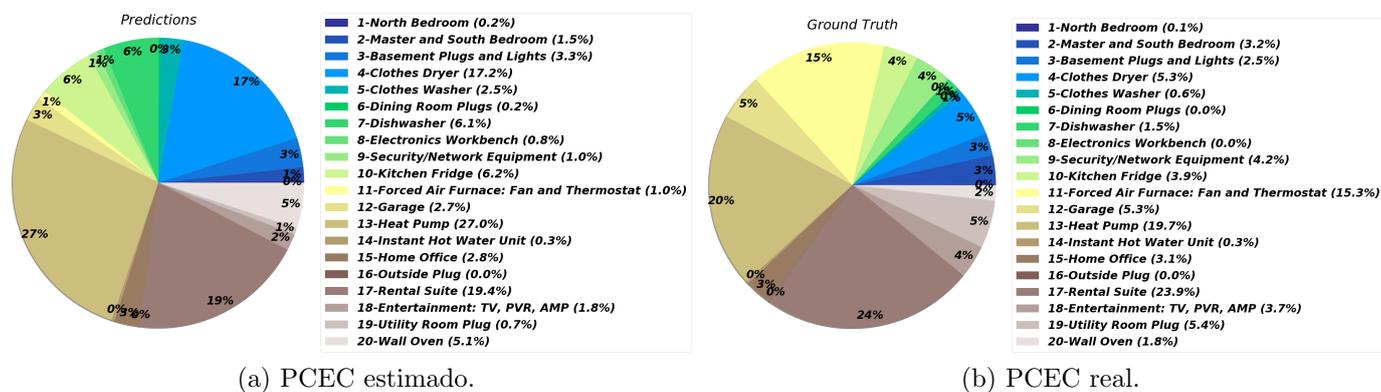


Figura C.7: Evolución de la loss al resolver $\min_{a \geq 0} \left\| \begin{bmatrix} x \\ \beta u \end{bmatrix} - \begin{bmatrix} D \\ \beta Q \end{bmatrix} a \right\|_2^2$ mediante A-PGD.



(a) PCEC estimado.

(b) PCEC real.

Figura C.8: PCEC problema con regularización S2K.

raba los resultados de PCEC sin generar que en el óptimo se obtenga únicamente a partir del término de regularización porque este tenga mucho peso.

La evolución de la loss se presenta en la Figura C.7.

El DE obtenido es 1,7A, siendo este inferior al caso sin S2K.

Los resultados de PCEC se encuentran en la Figura C.8.

En este caso se observan mejores resultados de PCEC, a costa de disminuir el DE. De todas formas el PCEC obtenido en algunos casos tiene fallas.

C.4.3.3. Con restricción S2K

La evolución de la loss para este problema se muestra en la Figura C.9.

El DE para este problema es 3,66A, el más alto de los 3, ya que se impone S2K como una restricción dura.

En tanto, el PCEC correspondiente a este problema es el de la Figura C.10.

Para este modelado, se obtienen excelentes resultados de PCEC, mientras que el peor DE de los tres.

C.4. Experimentos

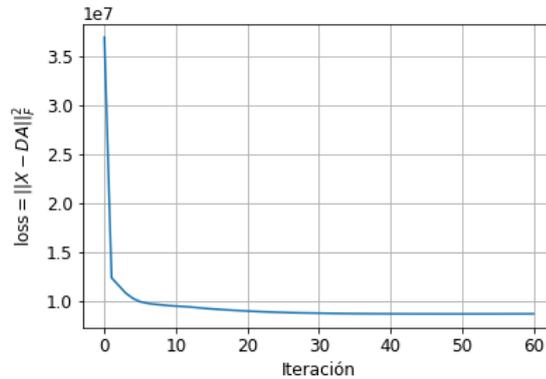
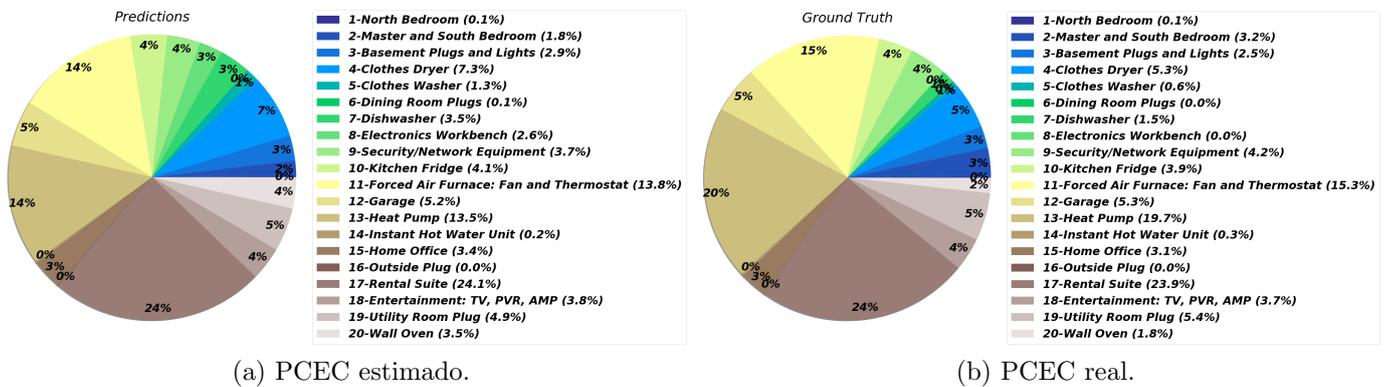


Figura C.9: Evolución de la loss al resolver de la Ecuación (C.7) mediante A-PGD.



(a) PCEC estimado.

(b) PCEC real.

Figura C.10: PCEC problema con restricción S2K.

C.4.3.4. Comparativa

Con fines de poder contrastar más claramente el DE y PCEC, se presentan los siguientes cuadros comparativos.

A modo de resumen, cuanto más se impone que se cumpla S2K más se mejora el PCEC, sin embargo se disminuye el DE. Esto se explica debido a que el DE indica que tan bien se reconstruye la señal agregada, no siendo esto lo que intenta hacer S2K. El objetivo de S2K es que se reconstruya mejor a las señales desagregadas a costa de una peor reconstrucción de la señal agregada.

	Regularización S2K	Restricción S2K	Sin regularización
DE	1.7 A	3.66 A	1.31 A

Tabla C.1: Tabla comparativa de DE.

Apéndice C. NMF aplicado a NILM

	Ground truth	Regularización S2K	Restricción S2K	Sin regularización
North Bedroom	0.12 %	0.23 %	0.08 %	7.69 %
Master and South Bedroom	3.25 %	1.50 %	1.80 %	0.53 %
Basement Plugs and Lights	2.51 %	3.26 %	2.87 %	5.66 %
Clothes Dryer	5.33 %	17.23 %	7.34 %	11.52 %
Clothes Washer	0.62 %	2.55 %	1.34 %	8.83 %
Dining Room Plugs	0.04 %	0.23 %	0.09 %	8.67 %
Dishwasher	1.48 %	6.12 %	3.49 %	5.10 %
Electronics Workbench	0.01 %	0.79 %	2.60 %	0.39 %
Security/Network Equipment	4.17 %	1.04 %	3.73 %	0.00 %
Kitchen Fridge	3.92 %	6.23 %	4.14 %	9.58 %
Forced Air Furnace: Fan and Thermostat	15.33 %	1.04 %	13.84 %	0.00 %
Garage	5.28 %	2.67 %	5.15 %	0.45 %
Heat Pump	19.74 %	26.95 %	13.53 %	19.58 %
Instant Hot Water Unit	0.29 %	0.32 %	0.24 %	12.50 %
Home Office	3.08 %	2.76 %	3.41 %	0.69 %
Outside Plug	0.00 %	0.01 %	0.04 %	0.01 %
Rental Suite	23.93 %	19.42 %	24.07 %	4.92 %
Entertainment: TV, PVR, AMP	3.75 %	1.84 %	3.80 %	0.30 %
Utility Room Plug	5.40 %	0.72 %	4.93 %	0.00 %
Wall Oven	1.76 %	5.09 %	3.54 %	3.58 %

Tabla C.2: Tabla comparativa de PCEC.

C.4.4. Resultados visuales

Por último, se presentan los resultados de desagregación de algunos electrodomésticos. Para cada uno de los problemas, se muestra la serie agregada obtenida y la serie desagregada para un *Lavavajillas*, *Heladera* y *Bomba de calor*.

En el caso del problema sin regularización y con regularización S2K se observa una reconstrucción de la señal agregada razonable, empeorando mucho en el caso de agregar S2K como restricción.

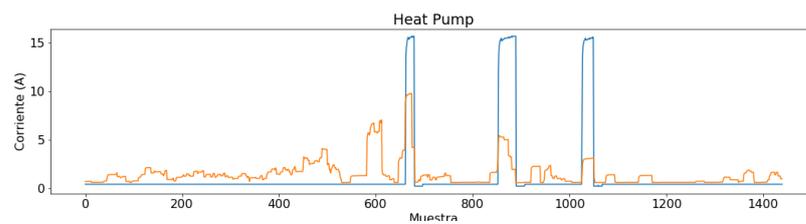
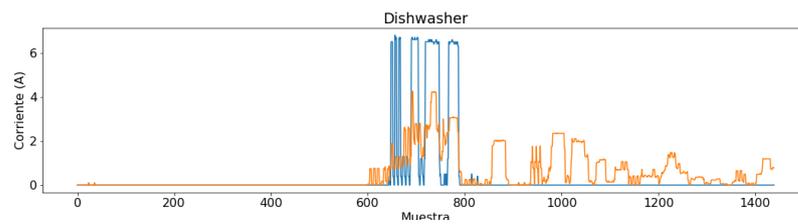
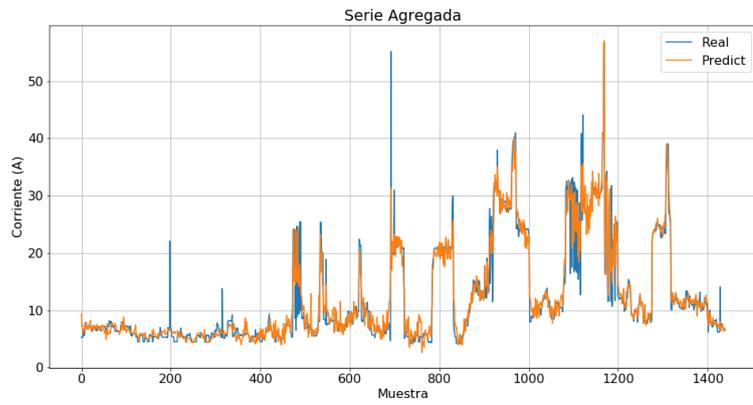
Mientras que para las señales desagregadas no parecen reconstruirse correctamente en ninguno de los casos. De todas maneras, al introducir S2K se aprecia una leve mejoría.

Las estimaciones de las señales desagregadas encontradas no son buenas, no lográndose mejorar la reconstrucción al añadir regularización.

A continuación, se presentan las figuras que muestran lo que se mencionó.

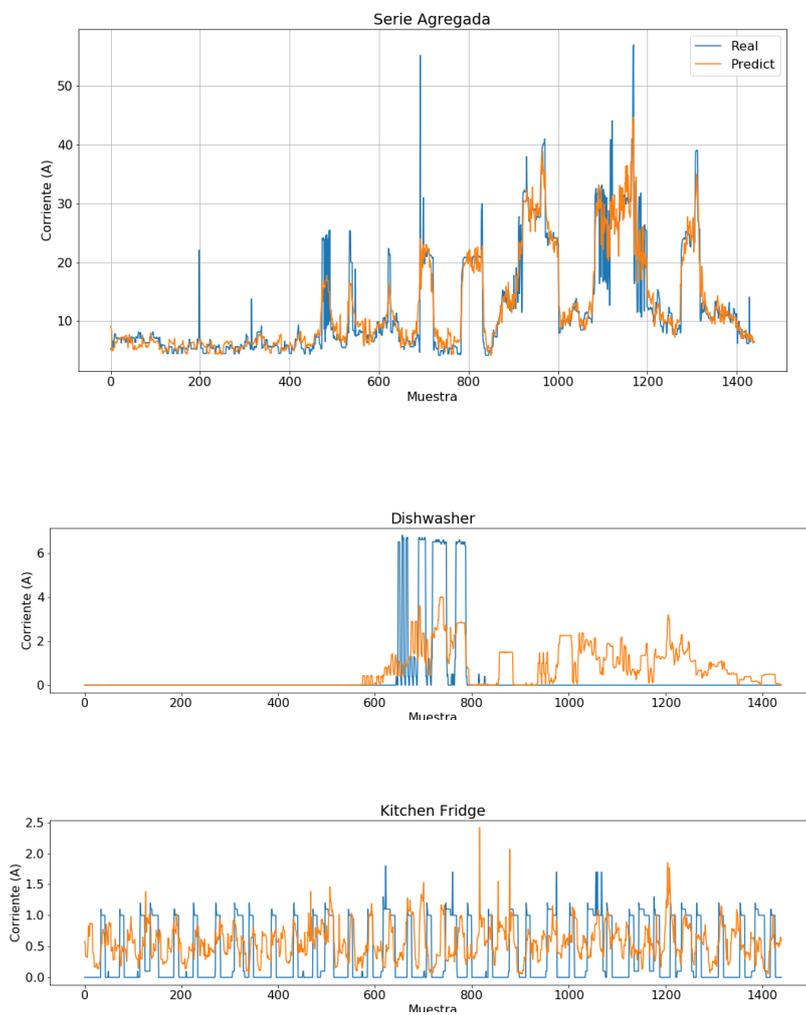
Sin restricción

C.4. Experimentos

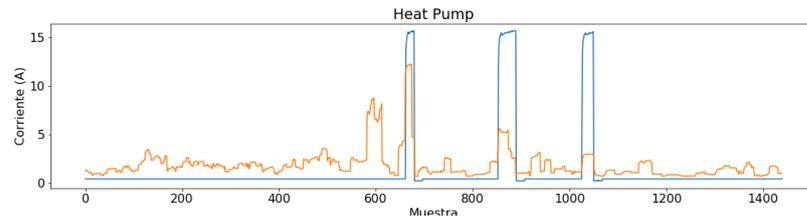


Apéndice C. NMF aplicado a NILM

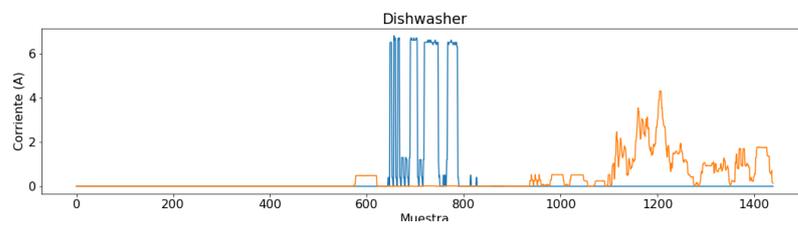
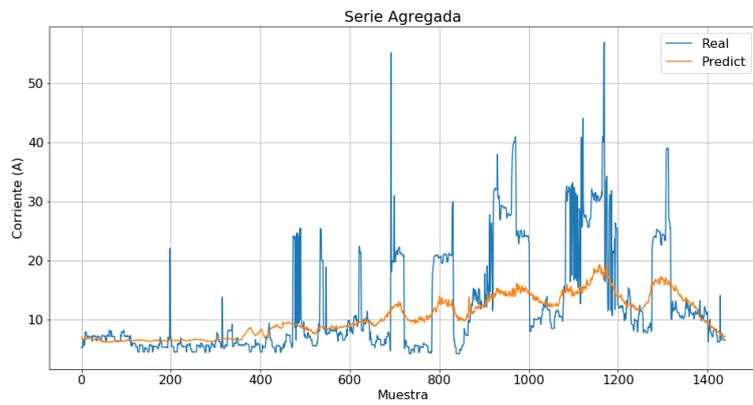
Regularización S2K



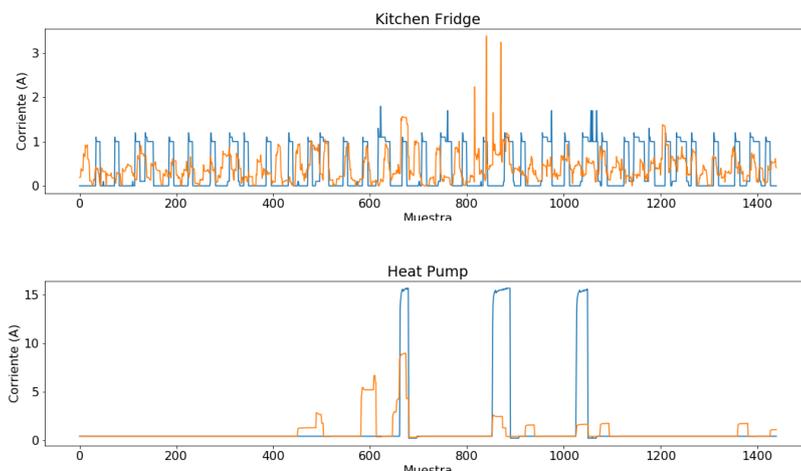
C.4. Experimentos



Restricción S2K



Apéndice C. NMF aplicado a NILM



C.5. Conclusiones

Se consiguió modelar NILM como un problema de optimización. Para esto se utilizó el enfoque novedoso S2K y se propuso una variante del mismo.

Se logró resolver el problema, lo cual fue un gran desafío, ya que utilizando software tradicional (CVXPY) y métodos clásicos (NNLS), el problema no era resoluble en un tiempo adecuado. Por esto, se implementó PGD y A-PGD para resolverlo de forma más eficiente. Con estos métodos de optimización se obtuvieron correctamente las soluciones de 3 problemas de optimización.

Tanto los tres algoritmos de optimización, junto con el pre y post procesamiento de los datos se encuentran disponibles en un repositorio GitHub público. A este se puede acceder desde https://github.com/camilomarino/Obligatorios_TAO_2020/tree/master/ProyectoFinal.

Se probó el modelado con una restricción sencilla sin regularización, obteniéndose malos resultados de PCEC. En cambio se tuvieron buenos resultados de DE. Esto se explica sencillamente porque se cuenta con varias bases \mathbf{d} de electrodomésticos que sus consumos son de tiempos muy pequeños (similares a deltas de valor finito), y a partir de estos se puede reconstruir cualquier señal.

Al agregar regularización se logró mejorar los resultados de PCEC, lo cual es deseado. Sin embargo, las figuras correspondientes a las señales desagregadas estimadas no son nada alentadoras. Se obtienen malos resultados de reconstrucción en todos los casos, mejorando levemente al utilizar cualquiera de las 2 variantes de S2K.

Para que el modelado planteado sea útil, se necesita una gran cantidad de datos, lo que conlleva a un costo computacional grande en la resolución del problema de optimización. Con 2 años de datos de una única casa no fue posible desagregar correctamente, lo que sugiere que este enfoque necesita aún más datos para poder capturar más firmas y así contemplar más patrones de consumo.

Como se mencionó en la Sección C.2, que consumos de un electrodoméstico en horarios distintos correspondan a una firma distinta es una gran limitante. Por lo que se concluye que sería de gran ayuda incluir en el modelado alguna forma de

tener en cuenta este corrimiento temporal. A la fecha, no existe ningún trabajo que aborde esta problemática desde el punto de vista de la resolución de un problema de optimización.

Lo implementado no logra reconstruir la señal desagregada. De todas formas, no se puede concluir que sea un enfoque que deba ser descartado. Para descartarlo se deberían explorar alternativas, algunas de ellas:

- Realizar búsqueda detallada del hiper-parámetro β .
- Filtrar la base de datos utilizada. Por ejemplo, eliminar los consumos tipo *delta* a la hora de entrenar.
- Modificar el largo de ventana. Se podría utilizar en lugar de un día, menos o más días.

Otros enfoque que se podría estudiar a futuro es modelar el problema sutilmente diferente. Por ejemplo, en trabajos como [140] o [141] se propone utilizar Non Negative Matrix Factorization (NNMF), el cual consiste en resolver un problema de optimización en dos variables, tanto se aprende la matriz \mathbf{X} como la matriz de firmas \mathbf{D} . Este es un enfoque no supervisado, en el sentido de que no se necesita tener las señales desagregadas para entrenar. El problema de optimización resultante sería el siguiente:

$$\min_{\mathbf{D} \geq 0, \mathbf{A} \geq 0} \|\mathbf{X} - \mathbf{DA}\|_F^2$$

Referencias

- [1] Stephan Renner, Mihaela Albu, Henk van Elburg, Christoph Heinemann, Artur Lazicki, Lauri Penttinen, Francisco Puente, and Hanne Saele. European smart metering landscape report. *Imprint*, 2:1–168, 2011.
- [2] George W Hart. Prototype nonintrusive appliance load monitor. In *MIT Energy Laboratory Technical Report, and Electric Power Research Institute Technical Report*. 1985.
- [3] G.W. Hart. Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, 80(12):1870–1891, 1992.
- [4] Michelle Susan Clark. *Improving the feasibility of energy disaggregation in very high-and low-rate sampling scenarios*. PhD thesis, University of British Columbia, 2015.
- [5] Hafiz Khurram Iqbal, Farhan Hassan Malik, Aoun Muhammad, Muhammad Ali Qureshi, Muhammad Nawaz Abbasi, and Abdul Rehman Chishti. A critical review of state-of-the-art non-intrusive load monitoring datasets. *Electric Power Systems Research*, 192:106921, 2021.
- [6] Hans Christian Gils. Assessment of the theoretical demand response potential in europe. *Energy*, 67:1–18, 2014.
- [7] Camilo Mariño, Guillermo Cossio, Pablo Massaferro, Matias Di Martino, Alvaro Gómez, and Alicia Fernandez. Nilmev: Electric vehicle disaggregation for residential customer energy efficiency incentives. In *2023 IEEE Power & Energy Society Innovative Smart Grid Technologies Conference (ISGT)*, pages 1–5. IEEE, 2023.
- [8] Camilo Mariño, Elías Masquil, Franco Marchesoni, Alicia Fernandez, and Pablo Massaferro. NILM: Multivariate DNN performance analysis with high frequency features. In *2021 IEEE PES Innovative Smart Grid Technologies Conference - Latin America (ISGT Latin America)*, pages 1–5, 2021.
- [9] Maria Kaselimi, Eftychios Protopapadakis, Athanasios Voulodimos, Nikolaos Doulamis, and Anastasios Doulamis. Towards trustworthy energy disaggregation: A review of challenges, methods, and perspectives for non-intrusive load monitoring. *Sensors*, 22(15):5872, 2022.

Referencias

- [10] Marisa Figueiredo. Contributions to electrical energy disaggregation in a smart home. *PhD, University of Coimbra*, 2013.
- [11] Jingkun Gao, Emre Can Kara, Suman Giri, and Mario Bergés. A feasibility study of automated plug-load identification from high-frequency measurements. In *Signal and Information Processing (GlobalSIP), 2015 IEEE Global Conference on*, pages 220–224. IEEE, 2015.
- [12] Srđan Dragomira Đorđević, Marko Dimitrijević, and Vančo Litovski. A non-intrusive identification of home appliances using active power and harmonic current. *Facta Universitatis, Series: Electronics and Energetics*, 30(2):199–208, 2016.
- [13] Leen De Baets, Chris Develder, Tom Dhaene, and Dirk Deschrijver. Detection of unidentified appliances in non-intrusive load monitoring using siamese neural networks. *International Journal of Electrical Power & Energy Systems*, 104:645–653, 2019.
- [14] A Longjun Wang, B Xiaomin Chen, C Gang Wang, and D Hua. Non-intrusive load monitoring algorithm based on features of v-i trajectory. *Electric Power Systems Research*, 157:134–144, 2018.
- [15] Zhuang Zheng, Hainan Chen, and Xiaowei Luo. A supervised event-based non-intrusive load monitoring for non-linear appliances. *Sustainability*, 10(4):1001, 2018.
- [16] Cheng Fan, Fu Xiao, Yang Zhao, and Jiayuan Wang. Analytical investigation of autoencoder-based methods for unsupervised anomaly detection in building energy data. *Applied energy*, 211:1123–1135, 2018.
- [17] Kofi Afrifa Agyeman, Sekyung Han, and Soohee Han. Real-time recognition non-intrusive electrical appliance monitoring algorithm for a residential building energy management system. *Energies*, 8(9):9029–9048, 2015.
- [18] Paula Meehan, Conor McArdle, and Stephen Daniels. An efficient, scalable time-frequency method for tracking energy usage of domestic appliances using a two-step classification algorithm. *Energies*, 7(11):7041–7066, 2014.
- [19] Reinhilde D’hulst, Wouter Labeeuw, Bart Beusen, Sven Claessens, Geert Deconinck, and Koen Vanthournout. Demand response flexibility and flexibility potential of residential smart appliances: Experiences from large pilot test in belgium. *Applied Energy*, 155:79–90, 2015.
- [20] Yu-Hsiu Lin and Men-Shen Tsai. Development of an improved time-frequency analysis-based nonintrusive load monitor for load demand identification. *IEEE Transactions on Instrumentation and Measurement*, 63(6):1470–1483, 2013.

- [21] Hsueh-Hsien Chang, Kuo-Lung Lian, Yi-Ching Su, and Wei-Jen Lee. Power-spectrum-based wavelet transform for nonintrusive demand monitoring and load identification. *IEEE Transactions on Industry Applications*, 50(3):2081–2089, 2013.
- [22] Sami Alshareef and Walid G Morsi. Application of wavelet-based ensemble tree classifier for non-intrusive load monitoring. In *2015 IEEE Electrical Power and Energy Conference (EPEC)*, pages 397–401. IEEE, 2015.
- [23] J Zico Kolter and Matthew J Johnson. REDD: A public data set for energy disaggregation research. In *Workshop on Data Mining Applications in Sustainability (SIGKDD)*, San Diego, CA, volume 25, pages 59–62. Citeseer, 2011.
- [24] Jack Kelly and William Knottenbelt. The UK-DALE dataset, domestic appliance-level electricity demand and whole-house demand from five UK homes. *Scientific data*, 2:150007, 2015.
- [25] Sean Barker, Aditya Mishra, David Irwin, Emmanuel Cecchet, Prashant Shenoy, Jeannie Albrecht, et al. Smart*: An open data set and tools for enabling research in sustainable homes. *SustKDD, August*, 111(112):108, 2012.
- [26] Hana Altrabalsi, Vladimir Stankovic, Jing Liao, and Lina Stankovic. Low-complexity energy disaggregation using appliance load modelling. *Aims Energy*, 4(1):884–905, 2016.
- [27] Suman Giri, Mario Bergés, and Anthony Rowe. Towards automated appliance recognition using an emf sensor in nilm platforms. *Advanced Engineering Informatics*, 27(4):477–485, 2013.
- [28] Jing Liao, Georgia Elafoudi, Lina Stankovic, and Vladimir Stankovic. Non-intrusive appliance load monitoring using low-resolution smart meter data. In *2014 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, pages 535–540. IEEE, 2014.
- [29] Bo Liu, Wenpeng Luan, and Yixin Yu. Dynamic time warping based non-intrusive load transient identification. *Applied energy*, 195:634–645, 2017.
- [30] Georgia Elafoudi, Lina Stankovic, and Vladimir Stankovic. Power disaggregation of domestic smart meter readings using dynamic time warping. In *2014 6th International Symposium on Communications, Control and Signal Processing (ISCCSP)*, pages 36–39. IEEE, 2014.
- [31] Kanghang He, Lina Stankovic, Jing Liao, and Vladimir Stankovic. Non-intrusive load disaggregation using graph signal processing. *IEEE Transactions on Smart Grid*, 9(3):1739–1747, 2016.

Referencias

- [32] Bochao Zhao, Kanghang He, Lina Stankovic, and Vladimir Stankovic. Improving event-based non-intrusive load monitoring using graph signal processing. *IEEE Access*, 6:53944–53959, 2018.
- [33] Kanghang He, Lina Stankovic, Jing Liao, and Vladimir Stankovic. Non-intrusive load disaggregation using graph signal processing. *IEEE Transactions on Smart Grid*, 9(3):1739–1747, 2018.
- [34] Hyungsul Kim, Manish Marwah, Martin Arlitt, Geoff Lyon, and Jiawei Han. Unsupervised disaggregation of low frequency power measurements. In *Proceedings of the 2011 SIAM international conference on data mining*, pages 747–758. SIAM, 2011.
- [35] J Zico Kolter and Tommi Jaakkola. Approximate inference in additive factorial hmms with application to energy disaggregation. In *Artificial Intelligence and Statistics*, pages 1472–1482, 2012.
- [36] Oliver Parson, Siddhartha Ghosh, Mark Weal, and Alex Rogers. An unsupervised training method for non-intrusive appliance load monitoring. *Artificial Intelligence*, 217:1–19, 2014.
- [37] Roberto Bonfigli, Emanuele Principi, Marco Fagiani, Marco Severini, Stefano Squartini, and Francesco Piazza. Non-intrusive load monitoring by using active and reactive power in additive factorial hidden markov models. *Applied Energy*, 208:1590–1607, 2017.
- [38] Alireza Rahimpour, Hairong Qi, David Fugate, and Teja Kuruganti. Non-intrusive energy disaggregation using non-negative matrix factorization with sum-to-k constraint. *IEEE Transactions on Power Systems*, 32(6):4430–4441, 2017.
- [39] Lidan Miao and Hairong Qi. Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization. *IEEE Transactions on Geoscience and Remote Sensing*, 45(3):765–777, 2007.
- [40] Pascal A Schirmer, Iosif Mporas, and Akbar Sheikh-Akbari. Energy disaggregation using two-stage fusion of binary device detectors. *Energies*, 13(9):2148, 2020.
- [41] Shikha Singh and Angshul Majumdar. Analysis co-sparse coding for energy disaggregation. *IEEE Transactions on Smart Grid*, 10(1):462–470, 2017.
- [42] Jack Kelly and William Knottenbelt. Neural nilm: Deep neural networks applied to energy disaggregation. In *Proceedings of the 2nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments*, pages 55–64. ACM, 2015.

- [43] Hasan Rafiq, Hengxu Zhang, Huimin Li, and Manesh Kumar Ochani. Regularized lstm based deep learning model: first step towards real-time non-intrusive load monitoring. In *2018 IEEE International Conference on Smart Energy Grid Engineering (SEGE)*, pages 234–239. IEEE, 2018.
- [44] Pedro Paulo Marques do Nascimento. Applications of deep learning techniques on nilm. *Diss. Universidade Federal do Rio de Janeiro*, 2016.
- [45] Gissella Bejarano, David DeFazio, and Arti Ramesh. Deep latent generative models for energy disaggregation. In *Proceedings of the AAAI Conference on Artificial Intelligence*, volume 33, pages 850–857, 2019.
- [46] Pedro BM Martins, José GRC Gomes, Vagner B Nascimento, and Antonio R de Freitas. Application of a deep learning generative model to load disaggregation for industrial machinery power consumption monitoring. In *2018 IEEE international conference on communications, control, and computing technologies for smart grids (SmartGridComm)*, pages 1–6. IEEE, 2018.
- [47] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. *Advances in neural information processing systems*, 30, 2017.
- [48] Zhenrui Yue, Camilo Requena Witzig, Daniel Jorde, and Hans-Arno Jacobsen. Bert4nilm: A bidirectional transformer model for non-intrusive load monitoring. In *Proceedings of the 5th International Workshop on Non-Intrusive Load Monitoring*, pages 89–93, 2020.
- [49] Jacob Devlin, Ming-Wei Chang, Kenton Lee, and Kristina Toutanova. Bert: Pre-training of deep bidirectional transformers for language understanding. *arXiv preprint arXiv:1810.04805*, 2018.
- [50] Stavros Sykiotis, Maria Kaselimi, Anastasios Doulamis, and Nikolaos Doulamis. Electricity: An efficient transformer for non-intrusive load monitoring. *Sensors*, 22(8):2926, 2022.
- [51] Nikolaos Virtsionis-Gkalinikis, Christoforos Nalmpantis, and Dimitris Vrakas. Saed: Self-attentive energy disaggregation. *Machine Learning*, pages 1–20, 2021.
- [52] Lingxiao Wang, Shiwen Mao, and R Mark Nelms. Transformer for nonintrusive load monitoring: Complexity reduction and transferability. *IEEE Internet of Things Journal*, 9(19):18987–18997, 2022.
- [53] Camilo Mariño, Elías Masquil, Franco Marchesoni, Alicia Fernandez, and Pablo Massaferrero. Nilm: Multivariate dnn performance analysis with high frequency features. In *2021 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America)*, pages 1–5. IEEE, 2021.

Referencias

- [54] Hasan Rafiq, Xiaohan Shi, Hengxu Zhang, Huimin Li, and Manesh Kumar Ochani. A deep recurrent neural network for non-intrusive load monitoring based on multi-feature input space and post-processing. *Energies*, 13(9):2195, 2020.
- [55] Yungang Pan, Ke Liu, Zhaoyan Shen, Xiaojun Cai, and Zhiping Jia. Sequence-to-subsequence learning with conditional gan for power disaggregation. In *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 3202–3206. IEEE, 2020.
- [56] Chaoyun Zhang, Mingjun Zhong, Zongzuo Wang, Nigel Goddard, and Charles Sutton. Sequence-to-point learning with neural networks for non-intrusive load monitoring. In *Proceedings of the AAAI conference on artificial intelligence*, volume 32, 2018.
- [57] Jing Zhang, Jiawei Sun, Jixiang Gan, Qi Liu, and Xioadong Liu. Improving domestic nilm using an attention-enabled seq2point learning approach. In *2021 IEEE Intl Conf on Dependable, Autonomic and Secure Computing, Intl Conf on Pervasive Intelligence and Computing, Intl Conf on Cloud and Big Data Computing, Intl Conf on Cyber Science and Technology Congress (DASC/PiCom/CBDCCom/CyberSciTech)*, pages 434–439. IEEE, 2021.
- [58] Guanchen Zhang, Gary Wang, Hassan Farhangi, and Ali Palizban. Residential electric load disaggregation for low-frequency utility applications. In *2015 IEEE Power & Energy Society General Meeting*, pages 1–5. IEEE, 2015.
- [59] Guanchen Zhang, G Gary Wang, Hassan Farhangi, and Ali Palizban. Data mining of smart meters for load category based disaggregation of residential power consumption. *Sustainable Energy, Grids and Networks*, 10:92–103, 2017.
- [60] Benjamin J Birt, Guy R Newsham, Ian Beausoleil-Morrison, Marianne M Armstrong, Neil Saldanha, and Ian H Rowlands. Disaggregating categories of electrical energy end-use from whole-house hourly data. *Energy and buildings*, 50:93–102, 2012.
- [61] Nipun Batra, Amarjeet Singh, and Kamin Whitehouse. Gemello: Creating a detailed energy breakdown from just the monthly electricity bill. In *Proceedings of the 22nd ACM SIGKDD international conference on Knowledge discovery and data mining*, pages 431–440, 2016.
- [62] Ayumu Miyasawa, Yu Fujimoto, and Yasuhiro Hayashi. Energy disaggregation based on smart metering data via semi-binary nonnegative matrix factorization. *Energy and Buildings*, 183:547–558, 2019.
- [63] Kaustav Basu, Vincent Debusschere, Seddik Bacha, Ujjwal Maulik, and Sanghamitra Bondyopadhyay. Nonintrusive load monitoring: A temporal multilabel classification approach. *IEEE Transactions on industrial informatics*, 11(1):262–270, 2014.

- [64] Vladimir Stankovic, Jing Liao, and Lina Stankovic. A graph-based signal processing approach for low-rate energy disaggregation. In *2014 IEEE symposium on computational intelligence for engineering solutions (CIES)*, pages 81–87. IEEE, 2014.
- [65] Kriti Kumar and M Girish Chandra. An intuitive explanation of graph signal processing-based electrical load disaggregation. In *2017 IEEE 13th International Colloquium on Signal Processing & its Applications (CSPA)*, pages 100–105. IEEE, 2017.
- [66] Christy Green and Srinivas Garimella. Very low-resolution residential load disaggregation with unsupervised graph signal processing. *Electric Power Systems Research*, 215:108998, 2023.
- [67] Bochao Zhao, Minxiang Ye, Lina Stankovic, and Vladimir Stankovic. Non-intrusive load disaggregation solutions for very low-rate smart meter data. *Applied Energy*, 268:114949, 2020.
- [68] Thierry Zufferey, Gustavo Valverde, and Gabriela Hug. Unsupervised disaggregation of water heater load from smart meter data processing. In *The 12th Mediterranean Conference on Power Generation, Transmission, Distribution and Energy Conversion (MEDPOWER 2020)*, volume 2020, pages 283–288. IET, 2020.
- [69] Apostolos Vavouris, Benjamin Garside, Lina Stankovic, and Vladimir Stankovic. Low-frequency non-intrusive load monitoring of electric vehicles in houses with solar generation: generalisability and transferability. *Energies*, 15(6):2200, 2022.
- [70] Andrés F Moreno Jaramillo, David M Laverty, Jesús Martínez del Rincón, John Hastings, and D John Morrow. Supervised non-intrusive load monitoring algorithm for electric vehicle identification. In *2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*, pages 1–6. IEEE, 2020.
- [71] Takekazu Kato, Hyun Sang Cho, Dongwook Lee, Tetsuo Toyomura, and Tatsuya Yamazaki. Appliance recognition from electric current signals for information-energy integrated network in home environments. In *Ambient Assistive Health and Wellness Management in the Heart of the City: 7th International Conference on Smart Homes and Health Telematics, ICOST 2009, Tours, France, July 1-3, 2009. Proceedings 7*, pages 150–157. Springer, 2009.
- [72] Frank Englert, Till Schmitt, Sebastian Köbler, Andreas Reinhardt, and Ralf Steinmetz. How to auto-configure your smart home? high-resolution power measurements to the rescue. In *Proceedings of the fourth international conference on Future energy systems*, pages 215–224, 2013.

Referencias

- [73] Steven B Leeb, Steven R Shaw, and James L Kirtley. Transient event detection in spectral envelope estimates for nonintrusive load monitoring. *IEEE Transactions on Power Delivery*, 10(3):1200–1210, 1995.
- [74] KH Ting, Mark Lucente, George SK Fung, WK Lee, and SYR Hui. A taxonomy of load signatures for single-phase electric appliances. In *IEEE PESC (Power Electronics Specialist Conference)*, pages 12–18, 2005.
- [75] Hong Yin Lam, GSK Fung, and WK Lee. A novel method to construct taxonomy electrical appliances based on load signatures. *IEEE Transactions on Consumer Electronics*, 53(2):653–660, 2007.
- [76] Hong-Tzer Yang, Hsueh-Hsien Chang, and Ching-Lung Lin. Design a neural network for features selection in non-intrusive monitoring of industrial electrical loads. In *2007 11th International Conference on Computer Supported Cooperative Work in Design*, pages 1022–1027. IEEE, 2007.
- [77] Yu-Hsiu Lin, Men-Shen Tsai, and Chin-Sheng Chen. Applications of fuzzy classification with fuzzy c-means clustering and optimization strategies for load identification in NILM systems. In *2011 IEEE international conference on fuzzy systems (FUZZ-IEEE 2011)*, pages 859–866. IEEE, 2011.
- [78] Jian Liang, Simon KK Ng, Gail Kendall, and John WM Cheng. Load signature study—part i: Basic concept, structure, and methodology. *IEEE transactions on power Delivery*, 25(2):551–560, 2009.
- [79] Adeel Abbas Zaidi, Friederich Kupzog, Tehseen Zia, and Peter Palensky. Load recognition for automated demand response in microgrids. In *IECON 2010-36th Annual Conference on IEEE Industrial Electronics Society*, pages 2442–2447. IEEE, 2010.
- [80] Andreas Reinhardt, Paul Baumann, Daniel Burgstahler, Matthias Hollick, Hristo Chonov, Marc Werner, and Ralf Steinmetz. On the accuracy of appliance identification based on distributed load metering data. In *2012 Sustainable Internet and ICT for Sustainability (SustainIT)*, pages 1–9. IEEE, 2012.
- [81] Paula Meehan, Shane Phelan, Conor McArdle, and Stephen Daniels. Temporal and frequency analysis of power signatures for common household appliances. In *Symposium on ICT and Energy Efficiency and Workshop on Information Theory and Security (CIICT 2012)*, pages 22–27. IET, 2012.
- [82] Matthias Kahl, Anwar Ul Haq, Thomas Kriechbaumer, and Hans-Arno Jacobsen. A comprehensive feature study for appliance recognition on high frequency energy data. In *Proceedings of the Eighth International Conference on Future Energy Systems*, pages 121–131. ACM, 2017.

- [83] Jingkun Gao, Suman Giri, Emre Can Kara, and Mario Bergés. PLAID: a public dataset of high-resolution electrical appliance measurements for load identification research: demo abstract. In *proceedings of the 1st ACM Conference on Embedded Systems for Energy-Efficient Buildings*, pages 198–199. ACM, 2014.
- [84] Dániel István Németh and Kálmán Tornai. Sp4lc: A method for recognizing power consumers in a smart plug. In *SMARTGREENS*, pages 69–77, 2022.
- [85] Dániel István Németh and Kálmán Tornai. Electrical load classification with open-set recognition. *Energies*, 16(2):800, 2023.
- [86] Radu-Casian Mihailescu, David Hurtig, and Charlie Olsson. End-to-end anytime solution for appliance recognition based on high-resolution current sensing with few-shot learning. *Internet of Things*, 11:100263, 2020.
- [87] Patricia Franco, Jose Manuel Martinez, Young-Chon Kim, and Mohamed A Ahmed. Iot based approach for load monitoring and activity recognition in smart homes. *IEEE Access*, 9:45325–45339, 2021.
- [88] Jack Kelly and William Knottenbelt. The uk-dale dataset, domestic appliance-level electricity demand and whole-house demand from five uk homes. *Scientific data*, 2(1):1–14, 2015.
- [89] Antonio Ridi, Christophe Gisler, and Jean Hennebert. A survey on intrusive load monitoring for appliance recognition. In *2014 22nd international conference on pattern recognition*, pages 3702–3707. IEEE, 2014.
- [90] Jean-Paul Zimmermann, Matt Evans, Jonathan Griggs, Nicola King, Les Harding, Penelope Roberts, and Chris Evans. Household electricity survey: A study of domestic electrical product usage. *Intertek Testing & Certification Ltd*, pages 213–214, 2012.
- [91] Stephen Makonin, Bradley Ellert, Ivan V Bajić, and Fred Popowich. Electricity, water, and natural gas consumption of a residential house in canada from 2012 to 2014. *Scientific data*, 3(1):1–12, 2016.
- [92] Nipun Batra, Oliver Parson, Mario Berges, Amarjeet Singh, and Alex Rogers. A comparison of non-intrusive load monitoring methods for commercial and residential buildings. *arXiv preprint arXiv:1408.6595*, 2014.
- [93] Oliver Parson, Grant Fisher, April Hersey, Nipun Batra, Jack Kelly, Amarjeet Singh, William Knottenbelt, and Alex Rogers. Dataport and nilmtk: A building data set designed for non-intrusive load monitoring. In *2015 ieee global conference on signal and information processing (globalsip)*, pages 210–214. IEEE, 2015.

Referencias

- [94] Marc Wenninger, Andreas Maier, and Jochen Schmidt. Deddiag, a domestic electricity demand dataset of individual appliances in germany. *Scientific Data*, 8(1):1–15, 2021.
- [95] Jesus L Lobo, Javier Del Ser, Miren Nekane Bilbao, Cristina Perfecto, and Sancho Salcedo-Sanz. Dred: An evolutionary diversity generation method for concept drift adaptation in online learning environments. *Applied Soft Computing*, 68:693–709, 2018.
- [96] Christian Beckel, Wilhelm Kleiminger, Romano Cicchetti, Thorsten Staake, and Silvia Santini. The eco data set and the performance of non-intrusive load monitoring algorithms. In *Proceedings of the 1st ACM conference on embedded systems for energy-efficient buildings*, pages 80–89, 2014.
- [97] Changho Shin, Eunjung Lee, Jeongyun Han, Jaeryun Yim, Wonjong Rhee, and Hyoseop Lee. The enertalk dataset, 15 hz electricity consumption data from 22 houses in korea. *Scientific data*, 6(1):1–13, 2019.
- [98] Sebastian Wilhelm, Dietmar Jakob, Jakob Kasbauer, and Diane Ahrens. Gelpap: German labeled dataset for power consumption. In *Proceedings of Sixth International Congress on Information and Communication Technology*, pages 21–33. Springer, 2022.
- [99] Andrea Monacchi, Dominik Egarter, Wilfried Elmenreich, Salvatore D’Alessandro, and Andrea M Tonello. Greend: An energy consumption dataset of households in italy and austria. In *2014 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, pages 511–516. IEEE, 2014.
- [100] Nipun Batra, Manoj Gulati, Amarjeet Singh, and Mani B Srivastava. It’s different: Insights into home energy consumption in india. In *Proceedings of the 5th ACM Workshop on Embedded Systems For Energy-Efficient Buildings*, pages 1–8, 2013.
- [101] Martin Pullinger, Jonathan Kilgour, Nigel Goddard, Niklas Berliner, Lynda Webb, Myroslava Dzikovska, Heather Lovell, Janek Mann, Charles Sutton, Janette Webb, et al. The ideal household energy dataset, electricity, gas, contextual sensor data and survey data for 255 uk homes. *Scientific Data*, 8(1):1–18, 2021.
- [102] Mohamed Aymane Ahajjam, Daniel Bonilla Licea, Chaimaa Essayeh, Mounir Ghogho, and Abdellatif Kobbane. Mored: A moroccan buildings’ electricity consumption dataset. *Energies*, 13(24):6737, Dec 2020.
- [103] Stephen Makonin, Z Jane Wang, and Chris Tumpach. Rae: The rainforest automation energy dataset for smart grid meter data analysis. *data*, 3(1):8, 2018.

- [104] David Murray, Lina Stankovic, and Vladimir Stankovic. An electrical load measurements dataset of united kingdom households from a two-year longitudinal study. *Scientific data*, 4(1):1–12, 2017.
- [105] Christoph Klemenjak, Christoph Kovatsch, Manuel Herold, and Wilfried Elmenreich. A synthetic energy dataset for non-intrusive load monitoring in households. *Scientific data*, 7(1):1–17, 2020.
- [106] Juan Chavat, Sergio Nesmachnow, Jorge Graneri, and Gustavo Alvez. Ecd-uy, detailed household electricity consumption dataset of uruguay. *Scientific Data*, 9(1):21, 2022.
- [107] Rodrigo Porteiro, Juan Chavat, Sergio Nesmachnow, and Luis Hernández-Callejo. Demand response control in electric water heaters: Evaluation of impact on thermal comfort. In *Ibero-American Congress of Smart Cities*, pages 74–89. Springer, 2020.
- [108] Santiago Garabedian, Rodrigo Porteiro, and Sergio Nesmachnow. Generation and classification of energy load curves using a distributed mapreduce approach. In *International Conference on Supercomputing in Mexico*, pages 3–17. Springer, 2019.
- [109] Rodrigo Porteiro, Sergio Nesmachnow, and Luis Hernández-Callejo. Short term load forecasting of industrial electricity using machine learning. In *Smart Cities: Second Ibero-American Congress, ICSC-CITIES 2019, Soria, Spain, October 7–9, 2019, Revised Selected Papers 2*, pages 146–161. Springer, 2020.
- [110] Franco Marchesoni, Camilo Mariño, and Elías Masquil. Monitoreo no intrusivo de cargas eléctricas (nilm). 2020.
- [111] Nipun Batra, Jack Kelly, Oliver Parson, Haimonti Dutta, William Knottenbelt, Alex Rogers, Amarjeet Singh, and Mani Srivastava. NILMTK: an open source toolkit for non-intrusive load monitoring. In *Proceedings of the 5th international conference on Future energy systems*, pages 265–276. ACM, 2014.
- [112] Jihyun Kim, Thi-Thu-Huong Le, and Howon Kim. Nonintrusive Load Monitoring Based on Advanced Deep Learning and Novel Signature. *Computational Intelligence and Neuroscience*, 2017:1–22, 2017.
- [113] Georgios-Fotios Angelis, Christos Timplalexis, Stelios Krinidis, Dimosthenis Ioannidis, and Dimitrios Tzovaras. NILM applications: Literature review of learning approaches, recent developments and challenges. *Energy and Buildings*, 261:111951, April 2022.
- [114] Zhiguang Wang, Weizhong Yan, and Tim Oates. Time series classification from scratch with deep neural networks: A strong baseline, 2016.

Referencias

- [115] Hassan Ismail Fawaz, Benjamin Lucas, Germain Forestier, Charlotte Peletier, Daniel F. Schmidt, Jonathan Weber, Geoffrey I. Webb, Lhassane Idoumghar, Pierre-Alain Muller, and François Petitjean. InceptionTime: Finding AlexNet for time series classification. *Data Mining and Knowledge Discovery*, 34(6):1936–1962, sep 2020.
- [116] Fazle Karim, Somshubra Majumdar, Houshang Darabi, and Samuel Harford. Multivariate lstm-fcns for time series classification. *Neural networks*, 116:237–245, 2019.
- [117] Zhiguang Wang, Weizhong Yan, and Tim Oates. Time series classification from scratch with deep neural networks: A strong baseline. *CoRR*, abs/1611.06455, 2016.
- [118] Kevin Fauvel, Tao Lin, Véronique Masson, Élisabeth Fromont, and Alexandre Termier. Xcm: An explainable convolutional neural network for multivariate time series classification. *Mathematics*, 9(23):3137, 2021.
- [119] Mohammad Hossin and Md Nasir Sulaiman. A review on evaluation metrics for data classification evaluations. *International journal of data mining & knowledge management process*, 5(2):1, 2015.
- [120] Ilya Loshchilov and Frank Hutter. Decoupled weight decay regularization, 2017.
- [121] Pascal A Schirmer and Iosif Mporas. Non-intrusive load monitoring: A review. *IEEE Transactions on Smart Grid*, 2022.
- [122] George William Hart. Nonintrusive appliance load monitoring. *Proceedings of the IEEE*, 80(12):1870–1891, 1992.
- [123] Georgios-Fotios Angelis, Christos Timplalexis, Stelios Krinidis, Dimosthenis Ioannidis, and Dimitrios Tzovaras. Nilm applications: Literature review of learning approaches, recent developments and challenges. *Energy and Buildings*, page 111951, 2022.
- [124] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization, 2014.
- [125] Leslie N. Smith. Cyclical learning rates for training neural networks, 2015.
- [126] Ignacio Oguiza. tsai - a state-of-the-art deep learning library for time series and sequential data. Github, 2022.
- [127] Adam Paszke, Sam Gross, Francisco Massa, Adam Lerer, James Bradbury, Gregory Chanan, Trevor Killeen, Zeming Lin, Natalia Gimelshein, Luca Antiga, et al. Pytorch: An imperative style, high-performance deep learning library. *Advances in neural information processing systems*, 32, 2019.

- [128] Sepp Hochreiter. The vanishing gradient problem during learning recurrent neural nets and problem solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 6(02):107–116, 1998.
- [129] Sepp Hochreiter and Jürgen Schmidhuber. Long short-term memory. *Neural computation*, 9(8):1735–1780, 1997.
- [130] Min Lin, Qiang Chen, and Shuicheng Yan. Network in network, 2013.
- [131] Christian Szegedy, Sergey Ioffe, Vincent Vanhoucke, and Alexander Alemi. Inception-v4, inception-resnet and the impact of residual connections on learning. In *Proceedings of the AAAI conference on artificial intelligence*, volume 31, 2017.
- [132] Andreas Reinhardt and Mazen Bouchur. *On the Impact of the Sequence Length on Sequence-to-Sequence and Sequence-to-Point Learning for NILM*, page 75–78. Association for Computing Machinery, New York, NY, USA, 2020.
- [133] A. Rahimpour, H. Qi, D. Fugate, and T. Kuruganti. Non-intrusive energy disaggregation using non-negative matrix factorization with sum-to-k constraint. *IEEE Transactions on Power Systems*, 32(6):4430–4441, 2017.
- [134] Steven Diamond and Stephen Boyd. CVXPY: A Python-embedded modeling language for convex optimization. *Journal of Machine Learning Research*, 17(83):1–5, 2016.
- [135] Charles L Lawson and Richard J Hanson. *Solving least squares problems*. SIAM, 1995.
- [136] Rasmus Bro and Sijmen De Jong. A fast non-negativity-constrained least squares algorithm. *Journal of Chemometrics*, 11(5):393–401, 1997.
- [137] Wikipedia. Non-negative least squares — Wikipedia, the free encyclopedia. <http://en.wikipedia.org/w/index.php?title=Non-negative%20least%20squares&oldid=993145058>, 2020. [Online; accessed 23-December-2020].
- [138] S. Makonin, F. Popowich, L. Bartram, B. Gill, and I. V. Bajić. Ampds: A public dataset for load disaggregation and eco-feedback research. In *2013 IEEE Electrical Power Energy Conference*, pages 1–6, 2013.
- [139] Nipun Batra, Jack Kelly, Oliver Parson, Haimonti Dutta, William Knottenbelt, Alex Rogers, Amarjeet Singh, and Mani Srivastava. Nilmtk: An open source toolkit for non-intrusive load monitoring. In *Proceedings of the 5th International Conference on Future Energy Systems, e-Energy '14*, page 265–276, New York, NY, USA, 2014. Association for Computing Machinery.

Referencias

- [140] Simon Henriët, Benoit Fuentes, Umut Şimşekli, and Gaël Richard. Matrix factorization for high frequency non intrusive load monitoring: Definitions and algorithms. In *Proceedings of the 5th International Workshop on Non-Intrusive Load Monitoring*, pages 20–24, 2020.
- [141] Shikha Singh and Angshul Majumdar. Deep sparse coding for non-intrusive load monitoring. *IEEE Transactions on Smart Grid*, 9(5):4669–4678, 2017.

Índice de tablas

3.1. Tabla comparativa de bases de datos.	30
4.1. Hiperparámetros utilizados en redes neuronales de clasificación. . .	52
4.2. Resultados de clasificación multiclase sobre el conjunto de entrena- miento y validación.	52
4.3. Resultados de clasificación multiclase para el mejor modelo, ResNet.	53
4.4. Resultados de clasificación binaria sobre el conjunto de entrena- miento y validación.	55
4.5. Resultados de clasificación binaria para el mejor modelo, ResNet. .	56
5.1. Resultados de desagregación a tasa de 15 minutos sobre termotanques.	69
5.2. Resultados de desagregación 15 minutal sobre termotanques. . . .	71
5.3. Resultados de desagregación a tasa de 15 minutos sobre vehículos eléctricos.	73
5.4. Resultados de desagregación 15 minutal sobre vehículos eléctricos.	75
5.5. Resultados de desagregación minutal sobre termotanques.	77
5.6. Resultados de desagregación minutal sobre termotanques.	79
5.7. Resultados de desagregación 15 minutal sobre termotanques al re- muestrear el modelo a tasa de 1 minuto.	81
6.1. Comparación entre la cantidad de termotanques y la tasa de acierto del algoritmo en producción. Datos proporcionados por el grupo de CI-UTE.	87
6.2. Comparación entre la cantidad de aires acondicionados y la tasa de acierto del algoritmo en producción. Tabla proporcionada por el grupo de CI-UTE.	87
C.1. Tabla comparativa de DE.	125
C.2. Tabla comparativa de PCEC.	126

Índice de figuras

1.1.	Serie histórica de generación y consumo de energía eléctrica en Uruguay. Datos extraídos del Catálogo de Datos Abiertos del Gobierno Uruguayo (https://catalogodatos.gub.uy/).	2
1.2.	Izquierda: Sonoff modelo IM160810001. Derecha: TI001-MC.	2
1.3.	Medidor inteligente Kaifa modelo <i>MA110P</i> colocado por UTE en los hogares de Uruguay.	3
1.4.	Esquema ILM y esquema NILM.	4
1.5.	Esquema de desagregación de consumo.	5
1.6.	Respuestas de la Encuesta Continua de Hogares 2022 sobre si se poseen determinados electrodomésticos.	7
1.7.	Esquema de identificación de electrodomésticos.	8
1.8.	Esquema de desagregación de electrodomésticos.	8
2.1.	Esquema de desagregación NILM usando la estrategia <i>event-based</i>	12
2.2.	Esquema de desagregación NILM usando <i>Deep Learning</i>	13
2.3.	Arriba: <i>seq2point</i> . Medio: <i>seq2subseq</i> . Abajo: <i>seq2seq</i>	15
3.1.	Series temporales de consumo del Hogar 1 de la base de datos UK-Dale para un día en particular.	20
3.2.	Series temporales de consumo para un hogar de la base de datos de termotanques en un día en particular.	26
3.3.	Series temporales de consumo para un hogar sintético de la base de datos de vehículos eléctricos en un día en particular.	27
3.4.	Serie temporal de consumo de un aire acondicionado de la base de datos de aires acondicionados en un día en particular.	28
3.5.	Series temporales de consumo de la casa 1 de la base de datos NILM-UY para un día en particular.	29
3.6.	Diagrama UML de las relaciones de los distintos objetos que interactúan en una base de datos NILM. Por más detalle ir a: https://nilm-metadata.readthedocs.io/en/latest/tutorial.html	31
3.7.	Flujo de trabajo partiendo de una base de datos en formato NILMTK-HDF.	31
3.8.	Esquema del protocolo de transferencia de datos acordado entre el grupo FING y UTE. Cada entidad (rectángulo) es un archivo CSV y los elementos enumerados dentro de este son las columnas del CSV.	34

Índice de figuras

3.9. Ejemplos de los distintos tipos de electrodomésticos. a) ON-OFF. b) Maquina de estado finita. c) Dispositivo de consumo variable. d) Dispositivo de consumo permanente	35
3.10. Ejemplos de los distintos tipos de electrodomésticos en tiempo largo. Ambas curvas son extraídas en el mismo periodo de tiempo, de un día y medio, de la base NILM-UY.	37
3.11. Ciclo de histéresis de un termotanque para calentar agua.	37
3.12. Estados de un termotanque.	38
3.13. Series temporales de consumo de termotanques a lo largo de un día de la base de datos UTEFING_TT con una muestra por minuto.	38
3.14. Series temporales de consumo de vehículos eléctricos a lo largo de un día de la base de datos UTEFING_VE. Una muestra cada 15 minutos.	39
3.15. Series temporales de termotanque, aire acondicionado, lavadora y heladera vistos a cuatro tasas de muestreo diferente. Cada columna corresponde a la misma curva de consumo a distinta tasa.	40
4.1. Esquema del algoritmo de clasificación de electrodomésticos con énfasis en la clasificación de termotanques.	42
4.2. Etapas para implementar el algoritmo de clasificación.	42
4.3. Esquema de separación diaria de datos para clasificación.	43
4.4. Series temporales de termotanque, aire acondicionado, lavadora y heladera re-muestradas a tasas de muestreo diferente. Cada columna corresponde a la misma curva de consumo a distinta tasa.	44
4.5. Gráfico de barras de la cantidad de datos por base de datos y por tipo de electrodoméstico (manteniendo los nombres de la taxonomía de NILMTK-HDF).	46
4.6. Gráfico de barras de la cantidad de “termotanque” y “no-termotanque”.	47
4.7. Configuraciones de clasificación de series temporales de electrodomésticos a distintas tasa de muestreo.	48
4.8. Configuraciones de clasificación binaria a partir de la configuración de clasificación multiclase.	49
4.9. Matriz de confusión sobre el conjunto de test normalizada a lo largo de las filas utilizando el modelo ResNet. Se muestran los 10 electrodomésticos con mayor cantidad de datos, mientras que la categoría “other” agrupa a todos los demás.	53
4.10. Probabilidades retornadas por el modelo ResNet al alimentarlo distintas series temporales del conjunto de test.	54
4.11. Características de la penúltima capa del modelo multiclase ResNet, aplicando reducción a dimensión 2 mediante t-SNE.	55
4.12. Evolución del F1-Score al incrementar la tasa de muestreo en el problema binario.	56
5.1. Diagrama bloques para implementar algoritmos de NILM.	58

5.2.	Series temporales de termotanques a tasa de 1 minuto y a tasa de 15 minutos. Cada columna corresponde a la misma curva de consumo a distinta tasa.	59
5.3.	Series temporales de vehículo eléctrico a tasa de 15 minutos.	59
5.4.	Esquema de separación diaria de datos para desagregación.	60
5.5.	Configuraciones para computar f^{-1} con distintos tamaños de entrada y salida.	63
5.6.	Esquema de la modificación introducida a la configuración c) en la que se agrega una etapa de post-procesamiento.	64
5.7.	Ejemplo de binarización de una curva de potencia de un termotanque adquirido cada 15 minutos con un umbral de 250W.	66
5.8.	Ejemplos de resultados de desagregación de termotanques para todos los modelos a tasa de 15 minutos sobre el conjunto de validación. En cada fila se tienen resultados para el mismo modelo, en cada columna se tiene las mismas señales para comparar los resultados. . .	70
5.9.	Curva ROC para la desagregación a tasa de 15 minutos sobre termotanques en el modelo BiLSTM. En rojo el punto de funcionamiento óptimo que maximiza el puntaje F1.	71
5.10.	Ejemplos de resultados de desagregación de termotanques para el mejor modelo, BiLSTM, sobre el conjunto de test.	72
5.11.	Ejemplos de resultados de desagregación de vehículos eléctricos para todos los modelos a tasa de 15 minutos. En cada fila se tienen resultados para el mismo modelo, en cada columna se tiene las mismas señales para comparar los resultados.	74
5.12.	Curva ROC para la desagregación a tasa de 15 minutos sobre vehículos eléctricos en el modelo BiLSTM. En rojo el punto de funcionamiento óptimo que maximiza el puntaje F1.	75
5.13.	Ejemplos de resultados de desagregación de vehiculos eléctricos para el mejor modelo, BiLSTM, sobre el conjunto de test.	76
5.14.	Ejemplos de resultados de desagregación de termotanques para todos los modelos a tasa de 1 minuto. En cada fila se tienen resultados para el mismo modelo, en cada columna se tiene las mismas señales para comparar los resultados.	78
5.15.	Curva ROC para la desagregación a tasa de 15 minutos sobre termotanques en el modelo BiLSTM. En rojo el punto de funcionamiento óptimo que maximiza el puntaje F1.	79
5.16.	Ejemplos de resultados de desagregación de termotanques a tasa de 1 minuto para el mejor modelo, BiLSTM, sobre el conjunto de test.	80
5.17.	Ejemplos de resultados de desagregación de termotanques a tasa de 15 minutos a partir de pos-procesar la salida del modelo BiLSTM a tasa de 1 minuto.	82
6.1.	Plataforma de clasificación de electrodomésticos desarrollada por el equipo de CI-UTE. Figura proporcionada por el grupo de CI-UTE.	86
6.2.	Comportamiento global de los clasificadores en la plataforma de CI-UTE. Figura proporcionada por el grupo de CI-UTE.	86

Índice de figuras

6.3. Resultados de la ejecución del algoritmo de desagregación del consumo de termotanques a nivel de una subestación de UTE. Figura proporcionada por el grupo de CI-UTE.	88
6.4. Histograma de consumo mensual de los termotanques en Uruguay.	89
6.5. Errores de estimación de consumo de energía mensual para termotanques.	89
6.6. Diagrama de cajas de los errores en la desagregación del consumo de termotanques a lo largo de un año para un cliente particular. Figura proporcionada por el grupo de CI-UTE.	90
6.7. Diagrama de cajas de los errores en la desagregación del consumo de termotanques a lo largo de un año para un cliente particular. Figura proporcionada por el grupo de CI-UTE.	90
6.8. Histograma de consumo mensual de los vehículos eléctricos en Uruguay.	91
6.9. Errores de estimación de consumo de energía mensual para vehículos eléctricos.	91
6.10. Histogramas de la probabilidad de ser termotanque. Figura proporcionada por el grupo de CI-UTE.	92
6.11. Esquema para imputar datos faltantes del medidor intrusivo a partir de la desagregación de consumo del medidor inteligente.	92
A.1. Arquitectura MLP para clasificación de electrodomesticos.	98
A.2. Esquema de un bloque de una red neuronal recurrente. Donde s_t es el estado y P_t la entrada	99
A.3. Arquitectura RNN para la clasificación de electrodomésticos. Varios bloques RNN seguidos de una última capa lineal.	99
A.4. Esquema de un bloque de una red neuronal recurrente de tipo LSTM. Donde s_t es el estado y P_t la entrada	100
A.5. Arquitectura LSTM para la clasificación de electrodomésticos. Varios bloques LSTM seguidos de una última capa lineal.	101
A.6. Arquitectura FCN para la clasificación de electrodomésticos.	102
A.7. Arquitectura ResNet para la clasificación de electrodomésticos.	102
A.8. Bloque Inception. Imagen extraída de [131].	103
A.9. Esquema de una red neuronal de tipo Autoencoder, compuesta por un bloque de Encoder y un bloque de Decoder.	105
A.10. Arquitectura BiLSTM para desagregacion de consumo. Dos LSTM apiladas seguidas de una última capa lineal.	106
B.1. Esquema de desagregación incluyendo el clasificador en el cálculo de la función de perdida.	111
C.1. Netesterov Momentum	119
C.2. Comparativa de la evolución de la loss entre PGD y A-PGD con matrices pequeñas.	120
C.3. Curva de corriente agregada correspondiente al primer día de consumo de la base AMPds.	121

C.4. Curva de corriente correspondiente a cada electrodoméstico del primer día de la base AMPds. 122

C.5. Evolución de la loss al resolver $\min_{a \geq 0} \|x - Da\|_2^2$ mediante A-PGD. 123

C.6. PCEC problema sin restricción. 123

C.7. Evolución de la loss al resolver $\min_{a \geq 0} \|[x\beta u] - [D\beta Q]a\|_2^2$ mediante A-PGD. 124

C.8. PCEC problema con regularización S2K. 124

C.9. Evolución de la loss al resolver de la Ecuación (C.7) mediante A-PGD.125

C.10.PCEC problema con restricción S2K. 125