



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO
PROGRAMA DE MAESTRÍA Y DOCTORADO EN INGENIERÍA
INGENIERÍA EN ENERGÍA - SISTEMAS ENERGÉTICOS

Dinámicas de Transacciones Energéticas en Micro Redes con
Generación Distribuida.

T E S I S

QUE PARA OBTENER EL GRADO DE:
DOCTOR EN INGENIERÍA

PRESENTA:

M.I. MARIO ANTONIO TOVAR ROSAS

DIRECTOR DE TESIS:

DR. MIGUEL ROBLES PÉREZ

TEMIXCO, MOR.

NOVIEMBRE 2022



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.



INSTITUTO DE ENERGÍAS RENOVABLES
UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

SINODALES Y COMITÉ TUTORAL:

SINODALES:

DRA. NADIA MARÍA SALGADO HERRERA
DRA. CELIA ANGELINA SÁNCHEZ PÉREZ
DRA. KARLA G. CEDANO VILLAVICENCIO
DR. OSCAR ALFREDO JARAMILLO SALGADO
DR. MIGUEL ROBLES PÉREZ

COMITÉ TUTORAL:

DRA. NADIA MARÍA SALGADO HERRERA
DR. MIGUEL ROBLES PÉREZ
DR. ROLANDO NIEVA GÓMEZ
DR. OSCAR ALFREDO JARAMILLO SALGADO
DR. AARÓN SÁNCHEZ JUÁREZ

Agradecimientos

Agradezco al CONACyT por la beca otorgada durante mis estudios. A mi familia, a mi esposa Léa, al Dr. Miguel Robles, a la Dra. Celia Sánchez, a la Dra. Karla Cedano, a la Dra. Nadia Salgado y al Dr. Oscar Jaramillo por constituir un grupo de sinodales con igualdad de género. Así mismo agradezco a todos los miembros de mi comité tutorial, como el Dr. AArón Sánchez y el Dr. Rolando Nieva; que me acompañaron con sus discusiones y consejos en este largo viaje. Finalmente me gustaría dedicar este trabajo en memoria de mi abuelo, el Ing. Austreberto Rosas Vásquez Q.D.E.P. Gracias por todos tus consejos y tu amor incondicional.

Resumen

La generación de energías renovables (REG, por sus siglas en inglés), está irrumpiendo en todo el mundo y apunta a ser el camino hacia un futuro energético sostenible. Sin embargo, debido a su propia naturaleza, estas fuentes variables presentan un desafío para su integración en la red de distribución.

En este trabajo se presentan cuatro casos de estudio, en el primero proponemos el uso de técnicas innovadoras de redes neuronales híbridas para hacer predicciones, en el segundo utilizamos las predicciones para cargar un sistema de almacenamiento de forma que se priorice la carga con recurso renovable, y la descarga en tanto que ayude a mitigar los picos de la demanda local, en el tercer caso, se incorporan unidades generadoras eólicas y solares y cada una con un sistema de almacenamiento en BCS, finalmente el último caso de estudio es un intento por plantear un problema de optimización de la variable económica.

El tercer caso de estudio es el núcleo de este trabajo, aquí se proponen itinerarios de carga y descarga de dos sistemas de almacenamiento de energía basados en baterías ideales (BESS, por sus siglas en inglés), el primero alimentado con un generador de energía solar fotovoltaica y el segundo alimentado con energía eólica. En la región de Baja California Sur (BCS).

Se propone el uso de predicciones para REG y demanda eléctrica (ED, por sus siglas en inglés), basados en un modelo de redes neuronales híbridas de tipo convolucionales y de memoria corta y larga en el tiempo (CNN-LSTM, por sus siglas en inglés), con estos modelos basados en datos, propondremos itinerarios precisos para saber cuándo cargar y cuando descargar la generación variable, buscando reducir la demanda eléctrica local en horas pico.

La red de convolución extraerá las características locales y la LSTM las temporales. Los itinerarios propuestos de carga y descarga en base a predicciones con el modelo híbrido CNN-LSTM, se compararán con itinerarios realizados con un modelo reconocido al igual que con itinerarios basado en puntos de observaciones reales de REG, para tener un punto de referencia.

Los resultados muestran que la integración de dos BESS con itinerarios de carga y descarga basados en un modelo CNN-LSTM, puede mitigar efectivamente dos picos importantes del perfil de demanda eléctrica en la ubicación estudiada.

Abstract

Renewable energy generation (REG) is irrupting throughout the globe and it points to be the path for a sustainable energy future. Nevertheless, due to their volatile nature, they present a challenge for integrating these intermittent sources into the grid.

In this work, 4 study cases are presented, in the first we propose the use of innovative techniques of hybrid neural networks to make predictions, in the second we use the predictions to load a storage system so that loading with renewable resources is prioritized, and the discharge as long as it helps to mitigate the peaks of the local demand, in the third case, wind and solar generating units are incorporated and each one with a storage system in BCS, finally the last studied case is an attempt to propose an optimization problem of the economic variable.

The third case of study is the core of this work, here charging and discharging itineraries of two ideal battery-based energy storage systems (BESS) are proposed, the first powered by a solar energy generator photovoltaic and the second powered by wind energy. In the region of Baja California Sur (BCS).

Using predictions for REG and electric demand (ED), based on a hybrid Convolutional Long-Short Time Memory (CNN-LSTM) neural network, we propose accurate itineraries to know when to charge and when to discharge variable REG, in the area of Baja California Sur (BCS) in Mexico, pursuing to reduce the ED in peak hours.

The convolution net will extract local features and the LSTM the temporal ones. The proposed itineraries of charge and discharge based on predictions with the hybrid CNN-LSTM model, are compared with itineraries made with a well known benchmark and itineraries based on true observations points of REG.

The results show that the integration of two BESS with charging and discharging itineraries based on a CNN-LSTM model, can effectively mitigate two important peaks of the electric demand profile in the studied location.

Índice general

Índice general	x
Apéndice A - Abreviaciones	xiii
Capítulo I	1
Introducción	1
Justificación	3
Objetivos	5
Estado del arte y conceptos básicos	6
Redes Neuronales Artificiales	11
Redes Neuronales Recurrentes	20
Métricas para evaluar el modelo	24
Predicciones	24
Sistemas BESS y la técnica de Rasurado de Picos	26
Capítulo II - Desarrollo	29
Caso de Estudio: Temixco, predicción de PVPG	29
Recurso solar en Temixco-Morelos	29
Caso de Estudio: Itinerarios de carga y descarga en Reino Unido	36
Modelo para el sistema de almacenamiento basado en un sistema de baterías ideales (BESS)	38
Caso de Estudio: Itinerarios en LCSN-BCS	40
Red eléctrica de BCS	45
Construcción del dataset y el modelo híbrido CNN-LSTM propuesto.	46
Variables climáticas en la zona de LCSN-BCS	47
Series de tiempo de generación renovable y demanda eléctrica en la zona de LCSN-BCS	48

<i>ÍNDICE GENERAL</i>	XI
Modelo híbrido CNN-LSTM	49
Capítulo III - Resultados	55
Predicciones para la demanda eléctrica.	55
Predicciones para generación fotovoltaica (PVPG).	57
Predicciones para generación eólica.	59
Itinerarios de carga y descarga en la zona de LCSN-BCS	62
Rasurado de picos con itinerarios de un BESS ideal basado en predicciones de un modelo CNN-LSTM en la zona de LCSN-BCS	68
Conclusiones	70
Capítulo IV: Mulegé - BCS.	73
Sistema Mulegé - Baja California Sur	74
Ventana de descarga en base a tarifas de CFE.	75
Variables climáticas en la región de Mulegé-BCS	76
Propuesta para el algoritmo de optimización en base a tarifas de CFE	77
Funcionamiento del algoritmo propuesto.	80
Capítulo V: Trabajo futuro.	83
Medidor de potencia eléctrica conectado a Internet	84
Datos recolectados	89
Propuesta para conmutación de cargas de forma remota	90
Apéndice B - Circuitos electrónicos para el medidor de potencia activa.	93
Bibliografía	95

Apéndice A - Abreviaciones

ARIMA	Autoregressive Integrated Moving Average. (Media móvil integrada autorregresiva.)
ANN	Artificial Neural Network. (Red Neuronal Artificial.)
BCS	Baja California Sur
BESS	Battery Energy Storage System. (Sistema de almacenamiento de energía con baterías.)
CAES	Compressed Air Energy Storage. (Almacenamiento de energía con aire comprimido.)
CENACE	Centro Nacional de Control de Energía
CNN	Convolutional Neural Network. (Red Neuronal Convolutiva.)
CONACyT	Consejo Nacional de Ciencia y Tecnología
CPU	Central Processing Unit. (Unidad de procesamiento central.)
DG	Distributed Generation. (Generación Distribuida.)
DHI	Diffuse Horizontal Irradiance. (Irradiancia difusa horizontal.)
DNI	Direct Normal Irradiance. (Irradiancia directa normal.)
ED	Electric Demand. (Demanda eléctrica.)
EESS	Electric Energy Storage System. (Sistema de almacenamiento de energía eléctrica.)
ESS	Energy Storage System. (Sistema de almacenamiento de energía.)
FC	Facultad de Ciencias - UNAM
GHI	Global Horizontal Irradiance. (Irradiancia global horizontal.)
GPU	Graphic Processing Unit. (Unidad de procesamiento gráfico.)

IER	Instituto de Energías Renovables
iot	internet of Things. (Internet de las cosas.).
LCSN	Los Cabos San Lucas
LSTM	Long-Short Term Memory. (Red neuronal de memoria de corto y largo plazo.)
MAE	Mean Absolute Error. (Error absoluto promedio.)
MG's	Microgrids. (Microrredes.).
ML	Machine Learning. (Aprendizaje automático.).
MSE	Mean Square Error. (Error cuadrático promedio)
NREL	National Renewable Energy Laboratory. (Laboratorio Nacional de Energías Renovables de Estados Unidos.)
ODE	Ordinary Differential Equation. (Ecuación diferencial ordinaria.)
PV	Photo Voltaic. (Fotovoltaico.)
PVPG	Photo Voltaic Power Generation. (Generación de potencia fotovoltaica.)
RE	Renewable Energy. (Energía Renovable.)
REG	Renewable Energy Generation. (Generación de energía renovable.)
ReLu	Rectified Linear Unit. (Unidad lineal rectificada.)
RMSE	Root Mean Square Error. (Raíz cuadrada del error cuadrático promedio.)
RNN	Recurrent Neural Network (Red Neuronal Recurrente.)
SAM	System Advisor Model. (Sistema para el asesoramiento de modelos.)
SPG	System Power Generated. (Potencia generada por el sistema.)
UNAM	Universidad Nacional Autónoma de México
WPG	Wind Power Generation. (Generación de potencia eólica.)

Capítulo I

Introducción

La creciente integración de los sistemas de generación de energía eléctrica basados en fuentes renovables implica nuevos retos para garantizar un suministro eléctrico eficiente, sostenible y seguro. En este sentido, el diseño de sistemas renovables integrados en el contexto de la generación distribuida (DG) y los Sistemas Inteligentes de Almacenamiento de Energía en Baterías (BESS), representan una alternativa para enfrentar estos desafíos [1, 2, 3]. Dependiendo de la generación y la demanda eléctrica presente y futura, se requerirán diferentes unidades de almacenamiento de energía, con diferentes tiempos de almacenamiento (carga/descarga), para garantizar un funcionamiento estable y confiable de la red eléctrica [4, 5]. El principal impulsor actual de la necesidad de almacenamiento de energía es el hecho de que las energías renovables en general, en particular la generación de energía fotovoltaica (PVPG) y la generación de energía eólica (WPG), están entrando cada vez más en el mercado eléctrico, mientras desplazan a las tecnologías convencionales [3]. De esta manera, un sector energético más sostenible e inteligente está surgiendo [6].

Sin embargo, es importante estudiar y analizar el carácter variable de estas nuevas fuentes de generación. En este trabajo se analizan cuatro casos de estudio donde se utilizan técnicas basadas en datos aplicados a la administración de micro-fuentes de energías renovables, también se incluye una propuesta para medir variables eléctricas y generar datasets propios. El primer caso es un problema de regresión utilizando redes neuronales en Temixco, Morelos. En segundo caso es una experiencia con datos de el Reino Unido y ahora se añade a la propuesta un sistema de almacenamiento. En el tercero (siendo este el más desarrollado en esta tesis) y cuarto caso de estudio, se analiza concretamente el impacto de la inclusión de fuentes de energía renovables y un sistema

de almacenamiento en un sistema eléctrico en específico: el sistema eléctrico BCS. Escogimos esta locación debido a que el sistema eléctrico de BCS está aislado del Sistema Eléctrico Nacional, esto significa que debe satisfacer su propia demanda eléctrica con generación local, lo que aumenta el impacto de las fuentes de generación renovables *in situ*. Además, hay que recordar que BCS cuenta con uno de los sistemas de generación eléctrica más contaminantes del país y con los precios más altos en las tarifas eléctricas [7, 8]; La irrupción de las energías renovables en un esquema de generación conjunta representa una opción con grandes beneficios. Por sus características, la zona BCS es un lugar con gran potencial para la implementación de DG con REG en el estado.

En otras palabras, existe un gran potencial en lo que a energías solar y eólica se refiere, aunado a un sistema eléctrico independiente. Es por esto que la generación de energía local renovable tiene una gran importancia en cuanto a su autonomía energética. Algunos estudios, como el realizado por el Laboratorio Nacional de Energías Renovables (NREL) de Estados Unidos, presentado en 2016 en el marco de la Alianza de Sistemas Eléctricos del Siglo XXI (21CPP), muestra que el área BCS tiene una gran potencial para la energía solar y eólica en particular (Fig. 1) [9].

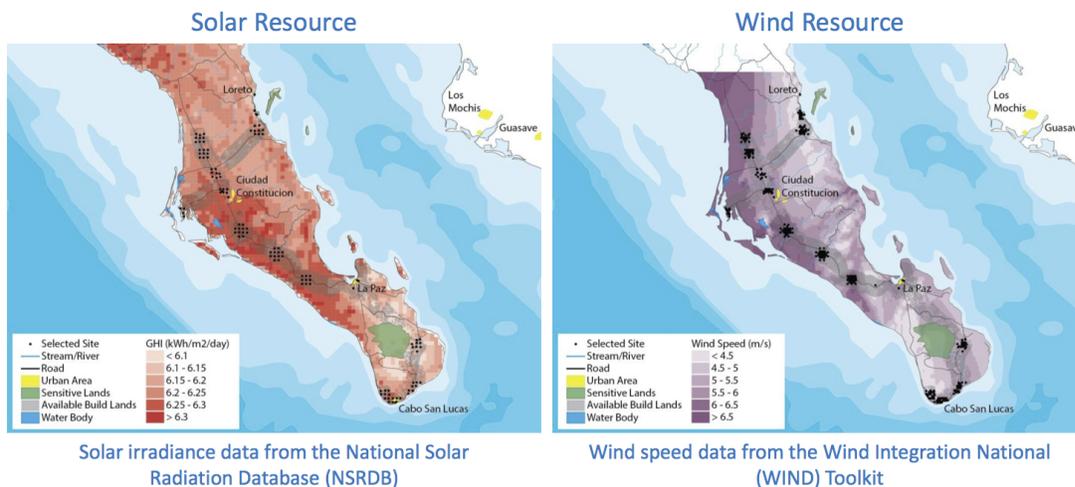


Figura 1: Recurso solar y eólico en la zona de BCS [9].

Considerando las características de BCS presentadas anteriormente, es evidente que la penetración de la generación eléctrica a partir de fuentes renovables puede representar un porcentaje importante en la región, lo que transformaría al sistema BCS de ser un sistema altamente contaminante a un sistema limpio, moderno y renovable. Por estas

razones, es necesario realizar estudios para incorporar técnicas novedosas como modelos de aprendizaje máquina ¹, para aumentar la confiabilidad y penetración de los sistemas de generación renovable en la red eléctrica, tratando de reducir los picos locales de demanda eléctrica con itinerarios precisos de carga y descarga. El objetivo principal de este trabajo es usar predicciones de un modelo basado en redes neuronales, para crear itinerarios de carga y descarga de electricidad en un caso de estudio donde las energías renovables provienen de dos fuentes que alimentan dos sistemas de almacenamiento de energía, para reducir los picos de la demanda local de energía eléctrica. Es mediante estos modelos predictivos y esquemas de administración de energía, que se propone entender las dinámicas de posibles transacciones energéticas ya que se estudian las unidades básicas de un modelo transactivo, las unidades generadoras y las unidades de almacenamiento.

Justificación

Hasta hoy en día el suministro eléctrico en México se ha basado en generación centralizada, generalmente utilizando combustibles fósiles de naturaleza no-renovable; con daños asociados al medio ambiente y pérdida de potencia debido a las grandes distancias en las líneas de transmisión [11]. La creciente integración de fuentes de energías renovables a la red eléctrica provee de una solución al dilema de energía limpia [12]. Sin embargo, la incertidumbre y la fluctuación en la generación renovable deben tomarse en cuenta [13].

Por otro lado, los mercados mayoristas existentes carecen de la capacidad de reaccionar en tiempo real a la generación volátil e intermitente de las energías renovables [14]. Además, los precios de mercado a menudo se determinan a nivel nacional, lo que no refleja la escasez de energía (local) o el exceso de oferta. Sin embargo, para apoyar la integración de recursos renovables distribuidos en el sistema energético, los nuevos enfoques de mercado deberían reflejar la localidad de sus servicios [15].

Los mercados energéticos de microrredes permiten a los participantes de pequeña escala, es decir, consumidores y prosumidores (consumidores que también producen

¹Del inglés: 'Machine Learning', una rama de la Inteligencia Artificial, que se enfoca en crear modelos basados en datos, de esta manera se busca que 'el agente' computacional 'aprenda' a extraer correlaciones complejas en problemas multi-variables [10]

energía), intercambiar activamente energía dentro de su comunidad en (casi) tiempo real (Fig.1). Por lo tanto, facilitan un equilibrio sostenible, confiable y local de generación y consumo. Esto representa una opción viable para integrar recursos renovables distribuidos en el sistema energético actual de una manera económica [5]. Además, esto empodera a los consumidores y prosumidores de energía a pequeña escala, incentiva las inversiones en la generación local y ayuda a desarrollar comunidades de micro-redes autosostenibles [15]. La implementación de los mercados de microrredes requiere sistemas de información innovadores, seguros e inteligentes [16], ya que son un factor esencial para su operación exitosa.

En la Fig.2 se muestra el escenario de una micro-red con recursos distribuidos. Por un lado consumidores convencionales y por el otro, prosumidores, almacenamiento y una capa de datos.

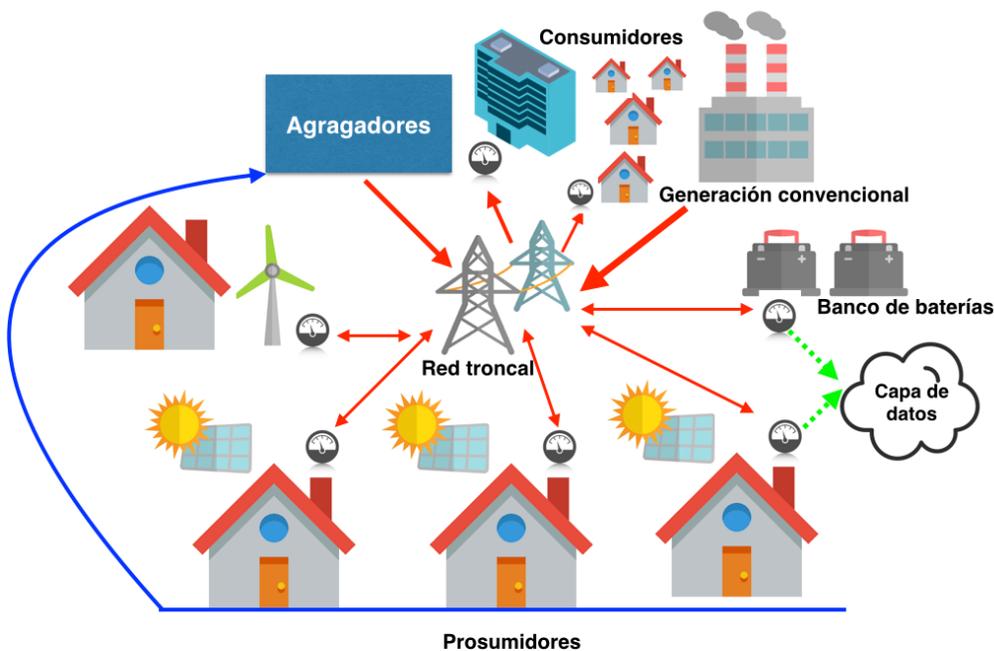


Figura 2: Escenario de una Red Inteligente con características acordes para un modelo transactivo.

Nótese que bajo este esquema se tienen agregadores, los cuales agrupan diversos prosumidores y generan acuerdos de compra venta en el mercado eléctrico [15]. Con todos

estos nuevos actores en juego, surge la necesidad de estudiar sus dinámicas tomando en cuenta los recursos distribuidos, la demanda, los sistemas de almacenamiento, interconexión a la red y la intermitencia del recurso energético y muchos otros temas más que entran en juego. De igual manera hay que recalcar que la existencia de una capa de información es esencial en este nuevo esquema. No se puede olvidar que en el caso de México, si bien actualmente, la digitalización de la red eléctrica nacional no es una realidad en lo absoluto, se menciona la digitalización como un punto importante a desarrollaren el Programa de Desarrollo del Sistema Eléctrico Nacional PRODESEN 2022 [17],.

Objetivos

Generar conocimiento para entender las posibles dinámicas de transacciones energéticas mediante predicciones de modelos basados en datos reales. Lo que se refiere a: datos climáticos, datos de generación fotovoltaica, generación eólica y demanda eléctrica en cuatro diferentes casos de estudio.

Objetivos específicos

- Desarrollar un modelo basado en datos para entender mediante predicciones, las dinámicas de posibles transacciones energéticas.
- Generar modelos computacionales con enfoques de frontera, basados en los datos climáticos de las zonas estudiadas, para predicciones de generación FV, generación eólica y demanda.
- Con estas predicciones se pretende diseñar y estudiar itinerarios de carga y descarga en las zonas estudiadas.
- Desarrollar e implementar herramientas para sensar variables eléctricas y transmitir las a servidores IoT (internet de las cosas).

Estado del arte y conceptos básicos

Conceptos básicos sobre microrredes y energía transactiva.

En esta sección abordaremos el tema de las microrredes así como la energía transactiva. Se entiende como una micro-red eléctrica a un grupo interconectado de cargas, así como diversos sistemas de generación distribuidos. La micro-red tiene fronteras eléctricas claramente definidas. Y sobre todo, actúa como una entidad independiente con respecto a la red troncal. Es decir, una micro-red puede conectar y desconectarse de la red (modo isla), operando de forma independiente en cualquier momento. Las micro-redes comprenden sistemas con recursos energéticos distribuidos (microturbinas hidroeléctricas, turbinas eólicas, generadores de combustible, energía fotovoltaica, etc.), así como sistemas de almacenamiento de energía y cargas flexibles. El funcionamiento de las micro fuentes en la red puede proporcionar distintos beneficios al rendimiento general del sistema, si se gestiona y se coordina de manera eficiente [18].

El concepto de energía transactiva es relativamente nuevo, pero podemos definirlo como un conjunto de aplicaciones de software para la administración de redes eléctricas. Éstas usan señales económicas e información operativa, para coordinar y manejar el consumo y/o generación de energía eléctrica [19].

Un ejemplo muy claro de la energía transactiva es el funcionamiento de termostatos en algunos países; éstos están conectados a una señal económica referente al precio de la energía eléctrica. Entonces, si la energía es barata, calientan, si la energía es cara, bajan la temperatura hasta cierto límite permitido [19].

Sin embargo, la energía transactiva no sólo consiste en dotar a los dispositivos con un control en base a una señal económica, también hace referencia a usar la propia energía como moneda de cambio, a esto se le conoce como una transacción energética[20].

Transacciones energéticas.

Para entender las transacciones energéticas usaremos como ejemplo la microrred de Brooklyn (BMG), en el trabajo de Mengelkamp y demás [15], se propone una archi-

tectura en la microrred capaz de soportar transacciones energéticas. Para diseñar esta microrred, los autores destacan 7 componentes esenciales:

- Preparación de la Micro-red (C1): Se definen los participantes del mini-mercado energético, así como el tipo de generación que se tendrá en la micro-red, adicionalmente se debe considerar si se usa la red eléctrica troncal para el transporte de energía o una micro-red física debe ser construida.
- Conexión física de la Micro-red (C2): Uno o varios puntos de interconexión hacia la red troncal son un componente clave [21], éstos deben estar bien definidos para equilibrar la generación de energía y la demanda dentro de la micro-red. Para el desacoplamiento y la operación en modo isla, las micro-redes necesitan una gran cantidad de capacidad propia de generación de energía y flexibilidad para garantizar un nivel apropiado de seguridad en el suministro. Como la energía es un flujo de electrones y se transmite en un medio de transmisión con límites físicos, problemas de flujo de energía, por ejemplo congestión en la red [22], deben tenerse en cuenta.
- Capa de Información (C3): Se necesita un sistema de información de alto rendimiento [23] para conectar a todos los participantes del mercado, proporcionar una plataforma para el mismo, así como dar acceso y monitoreo a las operaciones de este micro-mercado. Esto requiere un sistema de información eficiente y confiable que funcione en una resolución temporal adecuada. Debe implementarse de manera que todos los participantes del mercado tengan el mismo acceso. Un protocolo blockchain basado en contratos inteligentes puede cumplir con estos requisitos, aunque existen otras tecnologías adecuadas [24]. Tal protocolo blockchain puede verse como una infraestructura global compartida para aplicaciones descentralizadas que permite la implementación de aplicaciones de software a gran escala (contratos inteligentes) sin una plataforma central. Si bien la seguridad y la consistencia de los datos son rasgos inherentes de la tecnología blockchain [25], es necesaria una conexión segura desde los medidores inteligentes de los participantes del mercado, que miden y monitorean la generación y demanda de energía, hasta la cadena de bloques. Así los medidores inteligentes seguros pueden escribir los datos de energía requeridos directamente en las cuentas de blockchain correspondientes [26].

- Modelo de mercado (C4): Éste comprende las reglas de asignación y pago claramente definidas. El modelo de mercado es implementado por el sistema de información (C3). Su objetivo principal es proporcionar una asignación eficiente de la energía comercializada haciendo coincidir las órdenes de compra y venta de los participantes del mercado [27]. Idealmente, se deben implementar diferentes horizontes de tiempo de mercado para cubrir las diversas etapas de los mercados de energía eléctrica (por ejemplo, día a día o intradía). Los mecanismos de asignación deben adaptarse específicamente para dar como resultado una asignación eficiente para cada etapa. En este trabajo, nos centraremos en el comercio intradía y, por lo tanto, en el diseño de un mecanismo de mercado para esta etapa, con respecto al cumplimiento real de la demanda.
- Modelo de fijación de precios (C5): El mecanismo de fijación de precios se implementa a través del mecanismo de mercado (C4) y tiene como objetivo asignar eficientemente la oferta y la demanda de energía. Las subastas con precios de compensación uniformes o individuales a menudo sirven como mecanismos de fijación de precios para los mercados de energía [27]. Las señales de precios pueden usarse para indicar escasez o excedente de energía [27]. En consecuencia, un excedente de energía debería reducir el precio de la energía de la microred mientras que la falta de energía local aumenta el precio del mercado. Económicamente hablando, los mercados locales son beneficiosos para sus participantes siempre que el precio promedio de la energía sea más bajo que el precio de la red externa. Sin embargo, si se consideran las razones socioeconómicas (por ejemplo, el apoyo a la energía renovable local), el precio de la energía local puede incluso superar el precio de la red.
- Energy Management Trading System (EMTS) (C6): El principal objetivo del EMTS es asegurar automáticamente el suministro de energía para un participante del mercado. El EMTS necesita acceso a los datos de demanda y oferta (en tiempo real) de sus participantes en el mercado. En base a estos datos, el EMTS pronostica el consumo y la generación. Además, comercializa las cantidades previstas en la plataforma del mercado [15]. El EMTS también debe considerar los factores socioeconómicos (por ejemplo, compras preferidas de generación local renovable). A medida que el EMTS se hace cargo de la gestión energética y disminuye la carga del comercio de energía, aumentan simultáneamente la aceptación social del mercado energético comunitario [28]. El EMTS debe tener acceso a la cuenta

de blockchain de su participante en el mercado para facilitar automáticamente las transacciones de energía.

- Regulación legal (C7): Involucra todas las regulaciones del ámbito legal, propias de cada localidad.

En la Fig.3 se muestra un esquema para entender la topología de la BMG, en este nuevo esquema podemos observar que existen prosumidores, los cuales pueden actuar como consumidores normales en ciertos momentos, y en otros como pequeños generadores. Por esta razón se observa que los flujos eléctricos son bidireccionales.

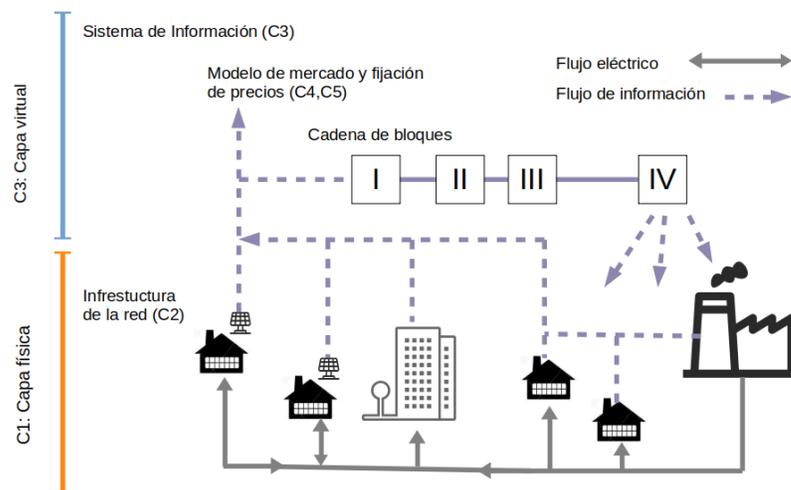


Figura 3: Topología de la micro-red de Brooklyn (BMG) [15].

En la Fig.4 se muestra que básicamente hay dos capas, una física (donde se encuentran prosumidores y consumidores) y otra de información, donde se tienen los esquemas de fijación de precios, reglas de pagos, órdenes de compra venta, etc.

En este caso el EMTS, es la entidad encargada de interactuar entre la capa física y la capa de información para poder realizar las transacciones energéticas. Su principal objetivo es garantizar energía para cualquier participante en la micro-red con un sistema de cobro específico.

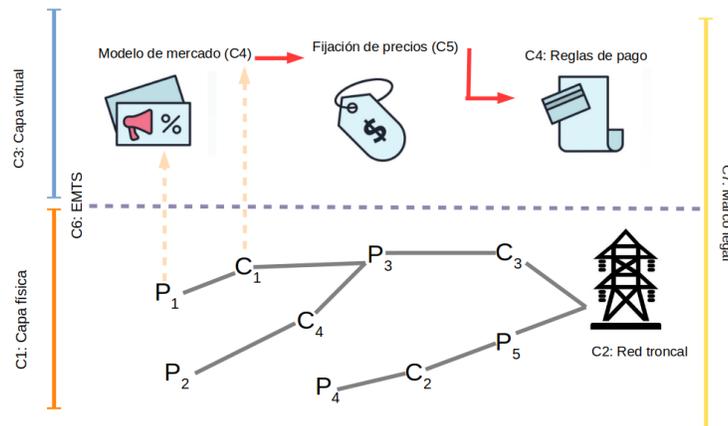


Figura 4: Representación gráfica de las transacciones energéticas realizadas en la BMG.
Fuente: [15]

Mercado Eléctrico Mayorista en México.

Cada país tiene sus características específicas en sus mercados eléctricos. En la Fig.5 se muestra la estructura del Mercado Eléctrico Mayorista (MEM) para el caso de México. Los participantes en este mercado son: los generadores, los suministradores, los comercializadores no suministradores y los usuarios calificados [29].

Como se puede observar, el Mercado de Corto Plazo se divide en servicios de Energía y Servicios Conexos. Para efectos de este trabajo, sólo mencionaremos que, según la legislación actual por la Comisión Reguladora de Energía (CRE) [30], si las estaciones generadoras superan los 500 [Kw], es necesario tomar el Mercado de Corto Plazo, específicamente en el Precio Marginal Local (PML). Se puede hacer uso de los Servicios Web para Descarga de Precios Marginales Locales (SW-PML) del CENACE.



Figura 5: Estructura del Mercados Eléctrico Mayorista en México. Fuente [29]

Redes Neuronales Artificiales

Las redes neuronales artificiales (ANN), son modelos novedosos basados en el funcionamiento de las neuronas biológicas, en el sentido que dadas ciertas entradas, se prenderán ciertos caminos sinápticos para asociar esa entrada a alguna emoción o concepto en específico. El objetivo principal de este modelo es aprender modificándose automáticamente a sí mismo, de forma que puede llegar a realizar tareas complejas que no podrían ser realizadas mediante la clásica programación basada en reglas [31]. De esta forma se pueden automatizar funciones que en un principio sólo podrían ser realizadas por personas. Para entender el funcionamiento de esas redes neuronales artificiales, se presenta a continuación el modelo de una neurona artificial simple (Fig. 6).

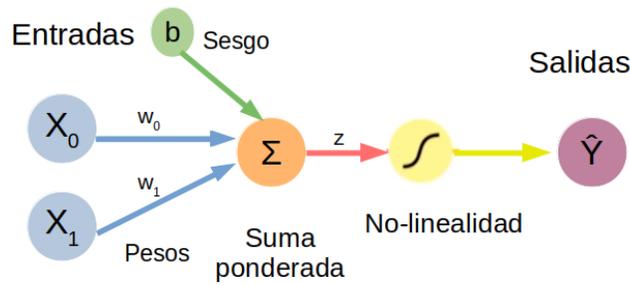


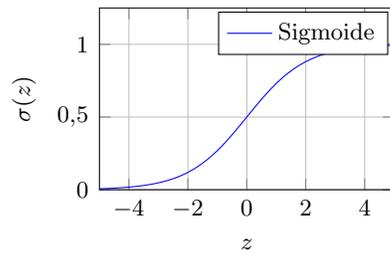
Figura 6: Modelo de Neurona Artificial, también llamado perceptrón.

Los elementos básicos que componen este modelo de neurona son los siguientes: Las entradas (X_0, X_1), podemos hacer la analogía con los estímulos de entrada que recibe una neurona biológica. Con estos valores de entrada la neurona realizará un cálculo interno (una suma ponderada donde $z = x_0 * w_0 + x_1 * w_1 + b$), después tenemos las funciones de activación (G) y finalmente la salida (\hat{Y}_n), la idea es que dada cierta entrada se generará una salida específica (Y_n). Uno de los parámetros más importantes en este modelo son los pesos (w_0, w_1), los cuales van a definir con qué intensidad cada variable de entrada afecta a la neurona [31]. Estos pesos son uno de los parámetros más importantes del modelo de neurona. A su vez tenemos el sesgo (b) mejor conocido como bias, en inglés. El sesgo en las redes neuronales se puede considerar análogamente al papel de una constante en una función lineal. Entonces, hasta este punto el modelo de neurona artificial es muy similar a un modelo de regresión lineal, por ejemplo. Sin embargo, justamente para añadir la no-linealidad al modelo, se introducen las llamadas funciones de activación (ver Fig.7).

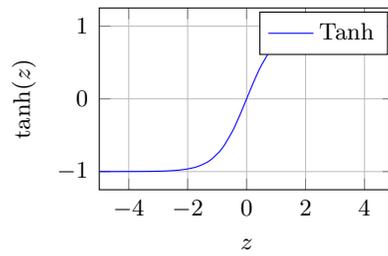
Hasta este punto entendemos que una red neuronal es un ensamblado de neuronas artificiales las cuales tienen como parámetros pesos (w_0, w_1), sesgos (b) y funciones de activación (G). De forma general se puede definir la salida de una neurona (Eq.1) de la siguiente manera:

$$\hat{Y}_n = (\hat{X}_n W_n + b)G \quad (1)$$

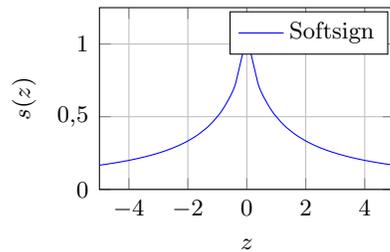
Como ya hemos mencionado, estos modelos reciben datos de entrada y queremos que para cada entrada (x_n) se genere una salida específica (Y_n). Para ello lo que se hace es introducir datos de entrenamiento en la red, en función del resultado que se obtenga, se modifican los pesos de las neuronas según el error obtenido (llamaremos función de



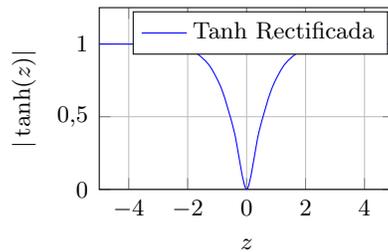
(a) Función de activación sigmoide.



(b) Función de activación tangente hiperbólica.



(c) Función de activación Softsign.



(d) Función de activación Tanh Rectificada.

Figura 7: Las funciones de activación más comunes incluyen el sigmoide logístico $\sigma(z)$ y la tangente hiperbólica $\tanh(z)$. Las funciones de activación Softsign y la tangente hiperbólica rectificada, se utilizan generalmente en procesamiento de lenguaje natural [32].

error o función de pérdida $J(w_0, w_1)$). Para disminuir este error se utiliza el método conocido como el descenso del gradiente (ver Fig.8). El cual se explica a continuación.

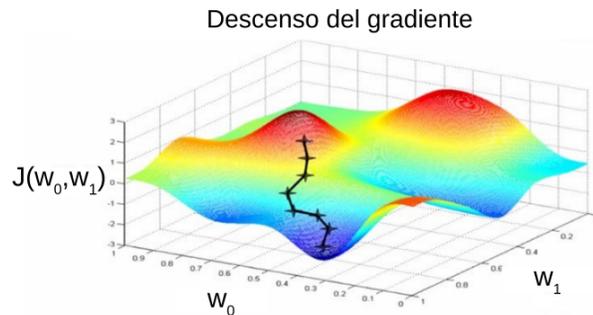


Figura 8: Descenso del gradiente, donde $J(w_0, w_1)$ es la función de error.

El algoritmo del descenso del gradiente es un proceso de optimización donde tie-

ne como objetivo el conjunto de pesos específicos (w_0, w_1) donde la función de error $J(w_0, w_1)$ se minimiza, este algoritmo funciona de la siguiente manera:

1. Primero se inicializan los pesos de forma aleatoria $\sim N(0, \sigma^2)$
2. Después se entra en el siguiente ciclo hasta la convergtencia:
 - Se hace el cómputo del gradiente para encontrar la dirección donde el error se maximiza: $\frac{\partial J(W)}{\partial W}$
 - Se actualizan los pesos: $W \leftarrow W - \eta \frac{\partial J(W)}{\partial W}$. El operador gradiente es una herramienta matemática que nos indica en qué dirección es la máxima razón de cambio de una función, con esta información podemos irnos en la dirección contraria para minimizar el error. La variable η es lo que se le conoce como la tasa de aprendizaje o learning rate en inglés, este parámetro nos va a decir de qué dimensión serán los pasos que estamos tomando en la sábana de la función de error $J(W)$ para no quedarnos atascados en un mínimo local [31].
3. Finalmente se regresan los pesos optimizados

Con este método se consigue que el error se minimice, sin embargo, dependiendo el problema, el paisaje o la sábana de la función de pérdida o función de error puede ser bastante compleja (ver Fig. 9).

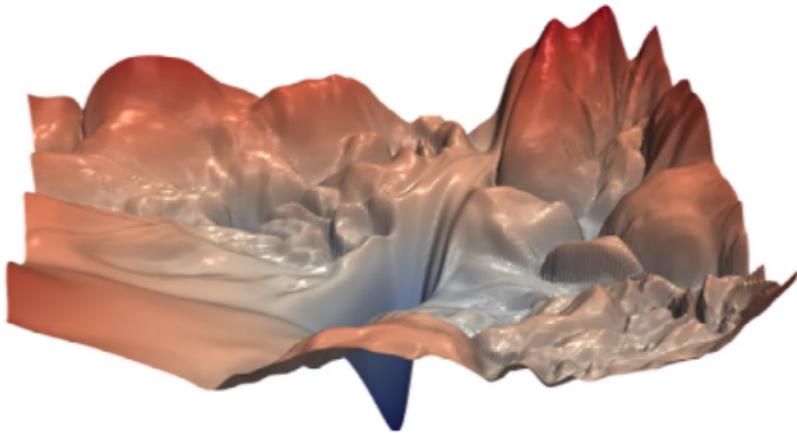


Figura 9: Paisaje de la función de pérdida en el entrenamiento de redes neuronales [33]

Actualmente paquetes como Tensorflow hacen automáticamente el cómputo del gradiente, sin embargo es importante explicar cómo se realiza este cómputo para cada uno

de los pesos en la red neuronal, este proceso es conocido como retropropagación hacia atrás o backpropagation en inglés. Para presentarlo vamos a pensar en una red neuronal con una sola entrada (Fig.10), en este caso la capa h se le denomina capa oculta que es la unión de la suma ponderada y la función de activación.



Figura 10: Modelo con una sola entrada y una sola capa oculta [31].

Para calcular el gradiente haremos uso de la regla de la cadena. En este caso vamos a aplicar la regla desde el error $J(W)$ para atrás. Si queremos encontrar cómo afecta una pequeña variación en w_1 al error $J(w)$ tendríamos que:

$$\frac{\partial J(W)}{\partial w_1} = \frac{\partial J(W)}{\partial \hat{Y}} * \frac{\partial \hat{Y}}{\partial h}. \quad (2)$$

Ahora si queremos encontrar cómo afecta la variación de w_0 a la función de error tenemos que:

$$\frac{\partial J(W)}{\partial w_0} = \frac{\partial J(W)}{\partial w_1} * \frac{\partial h}{\partial w_0}, \quad (3)$$

y como ya habíamos calculado el gradiente de w_1 con respecto al error $J(W)$ tenemos finalmente que:

$$\frac{\partial J(W)}{\partial w_0} = \frac{\partial J(W)}{\partial \hat{Y}} * \frac{\partial \hat{Y}}{\partial h} * \frac{\partial h}{\partial w_0}. \quad (4)$$

Dicho de una forma intuitiva el algoritmo de retropropagación hacia atrás nos dice cómo usar el error de la capa anterior para calcular el error de la capa actual. Con estos errores podemos computar finalmente el gradiente (eq. 4)[31].

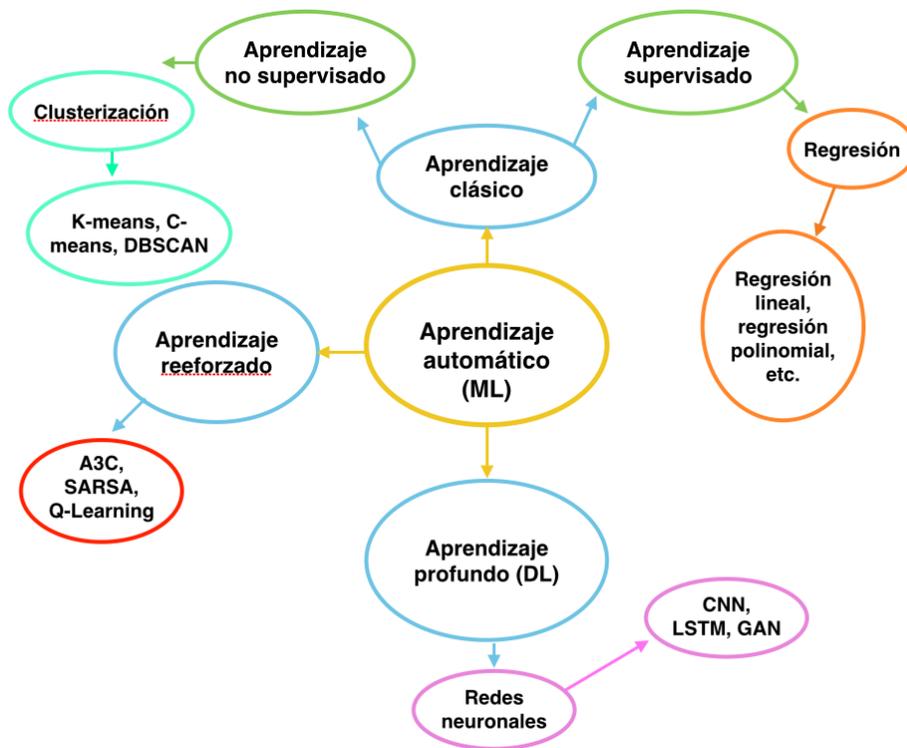


Figura 11: Diagrama general de métodos de aprendizaje automático.

El aprendizaje automático o aprendizaje máquina (ML) es un área de las ciencias computacionales, que proporciona a las computadoras la capacidad de aprender, sin ser programadas explícitamente. El aprendizaje automático se centra en el desarrollo de programas informáticos que pueden cambiar cuando se exponen a nuevos datos. Éste a su vez encuentra subdivisiones como el aprendizaje clásico, el aprendizaje reforzado, el aprendizaje profundo (DL), entre otras [34].

Como se puede observar en la Fig.11, el aprendizaje clásico a su vez, se puede dividir en aprendizaje supervisado que comprende técnicas como la regresión polinomial o la regresión lineal múltiple [35].

En el aprendizaje no supervisado podemos encontrar técnicas de clusterización. Dentro de las técnicas de clusterización, Podemos destacar el algoritmo de K-means, C-means, DBSCAN, etc [34].

En las últimas década debido al avance en la tecnología de procesamiento de datos

computacionales, han surgido técnicas basadas en ML. Dentro de este grupo podemos encontrar el aprendizaje profundo (DL), aquí podemos resaltar las redes neuronales convolucionales (CNN), redes neuronales recurrentes (RNN), etc. Muchos autores han utilizado estas técnicas para procesar series temporales y generar predicciones con una alta precisión [35] [36] [37]. Se hablarán de estas técnicas en el siguiente capítulo.

Algunos autores han obtenido predicciones de generación FV utilizando modelos basados en datos, reportando excelentes resultados [37]. Este enfoque basado en datos para generar predicciones de generación FV funciona perfectamente en un esquema de redes inteligentes, donde la capa de información es esencial para la toma de decisiones en la administración de la energía.

En cuanto a los pronósticos de demanda, en México el Centro Nacional de Control de Energía (CENACE), utiliza diversas metodologías para hacer sus pronósticos, como son: promedio móvil simple, promedio móvil ponderado y regresiones lineales múltiples [29]. Por lo que la utilización de las técnicas de ML para predicción de demanda eléctrica, al menos en lo que a México se refiere, todavía son novedosas.

Cabe añadir que estos perfiles que tiene CENACE en su plataforma pública son globales para cada región del SEN, es decir, no se tienen datos en México que reflejen localidad de la demanda. Por otro lado, también son estáticos. La incorporación de un sistema de monitoreo en los puntos finales de consumo, permitiría tener perfiles dinámicos y a su vez un control dinámico para lograr flexibilidad tanto en la generación como en la demanda.

En las siguientes dos secciones abordaremos la explicación formal en específico de dos tipos de redes neuronales que se utilizaron en el desarrollo de este trabajo: redes neuronales convolucionales (CNN) y las redes de memoria larga y corta (LSTM).

Extracción de características esenciales con redes neuronales convolucionales (CNN).

La CNN es un tipo de Red Neuronal Artificial con aprendizaje supervisado que procesa sus capas imitando al cortex visual del ojo humano para identificar distintas características en las entradas que en definitiva hacen que pueda identificar objetos y

“ver”. Para ello, la CNN contiene varias capas ocultas especializadas y con una jerarquía: esto quiere decir que las primeras capas pueden detectar líneas, curvas y se van especializando hasta llegar a capas más profundas que reconocen formas complejas como un rostro o la siluetas. Para poder explicar estas redes convolucionales seguiremos usando el ejemplo en procesamiento de imágenes ya que son muy populares para extraer características locales en esta rama [38].

La convolución es el concepto principal de una CNN. La misma idea de la convolución matemática se aplica para entender el proceso de las CNN, de forma intuitiva en el proceso de convolución de dos señales, por ejemplo, se tiene una multiplicación y una suma ordenada de sus elementos. En las CNN se aplica la convolución con una imagen de pixeles por ejemplo y un kernel (el kernel lo podemos ver como un filtro personalizable), al hacer la convolución elemento a elemento, reducimos el tamaño de nuestra matriz de pixeles original y es así como se logra la extracción de características esenciales (Fig 12).

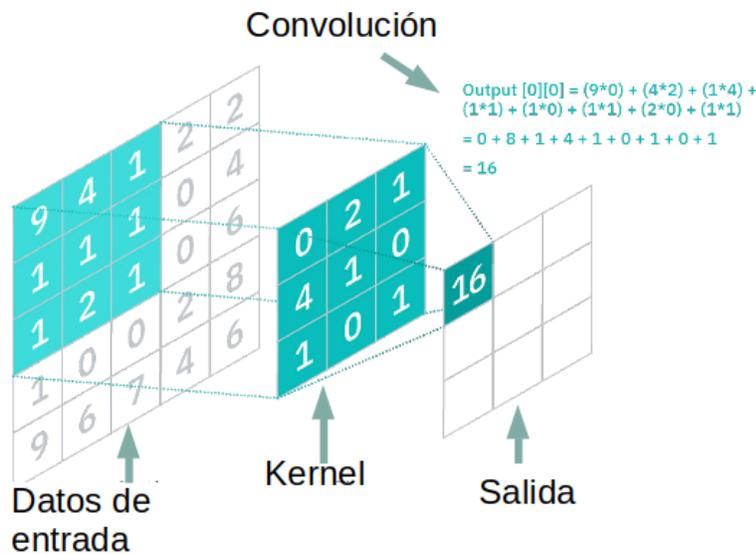


Figura 12: Relación entre la convolución y su uso en las redes CNN [31].

La CNN propuesta incluye de dos partes: las capas convolucionales (Eq.2. y Eq.3.) y la capa de agrupación, mejor conocida como Max Pooling (el objetivo principal de esta

capa es reducir la cantidad de parámetros del tensor reduciendo su tamaño Fig.13), por lo tanto, esta capa de agrupación ayuda a disminuir el tiempo de cálculo.

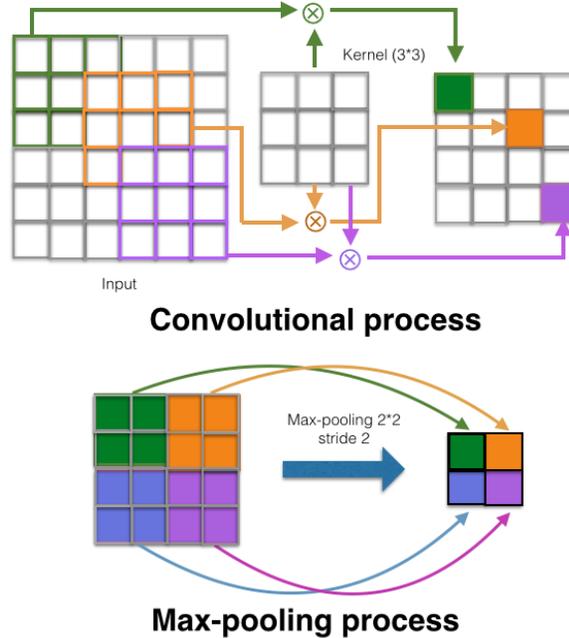


Figura 13: Convolución y el proceso de Max-pooling, imagen adaptada de [37].

Ahora comienza el “procesado distintivo” de las CNN. Es decir, haremos las llamadas “convoluciones”: Estas consisten en tomar “grupos de pixeles cercanos” de la imagen de entrada e ir operando matemáticamente (producto escalar) contra una pequeña matriz que se llama kernel. Ese kernel supongamos de tamaño 3×3 pixels “recorre” todas las neuronas de entrada (de izquierda-derecha, de arriba-abajo) y genera una nueva matriz de salida, que en definitiva será nuestra nueva capa de neuronas ocultas.

En la capa de convolución, la matriz de características de la capa anterior interactúa con el núcleo convolucional; esta interacción forma la matriz de características de salida j de la capa convolucional. Cada uno de estas matrices de características de salida j podría contener una convolución con varias matrices de características de entrada.

Las ecuaciones que definen la capa de convolución son:

$$y_j^{(l)} = \left(\sum_{i \in c_j} t_i^{l-1} \otimes w_{ij}^{(l)} \right) + b_j^{(l)}. \quad (5)$$

Donde \otimes es el operador convolución, c_j es el conjunto de matrices características de entrada (input), b_j^l es el sesgo (bias en inglés), $w_{ij}^{(l)}$ el kernel convolucional y y_j^l es la salida (output) de la convolución.

$$t_j^l = f(y_j^{(l)}), \quad (6)$$

t_j^l es la matriz de características de la capa convolucional l .

$$f(x) = \max(0, x), \quad (7)$$

f es la función de activación. En este trabajo usaremos una unidad lineal rectificadora (Relu - Rectified linear unit) definida en la ecuación (3), para la parte convolucional).

Como mencionamos anteriormente, el núcleo de la extracción de características esenciales es la convolución, ésta funciona al reducir la cantidad de características en un conjunto de datos. Este nuevo conjunto reducido de características esenciales debería poder resumir la mayor parte de la información contenida en el conjunto original de entrada. De esta forma, gracia a estas capas, tendremos una versión resumida de las características originales [39, 36, 40].

Como veremos en el Capítulo 7.3, la extracción de características del modelo híbrido funciona así: en primer lugar, la capa superior de CNN-LSTM consta de CNN. La capa CNN puede recibir diversas variables que afectan a los fenómenos estudiados, como por ejemplo las variables meteorológicas en nuestro caso. Por lo tanto, CNN consta de una capa de entrada que acepta múltiples variables como entradas y una capa de salida que extrae características a LSTM y varias capas ocultas. Luego, las capas LSTM podrán extraer características complejas entre múltiples variables y almacenar tendencias irregulares complejas en el tiempo. En otras palabras, después del entrenamiento, cada peso del modelo CNN-LSTM corresponderá a una determinada entrada.

Redes Neuronales Recurrentes

Cuando usamos una red neuronal simple, la respuesta de la red es independiente a los datos que ha evaluado anteriormente. Es decir, no se espera que tenga memoria de lo que ha procesado y su respuesta no depende de los datos procesados anteriormente. La idea de las RNN (Redes Neuronales Recurrentes) es hacer uso de la información

secuencial. Es decir, este tipo de redes neurales se usa para procesar datos en los cuales hay una dependencia temporal de los datos procesados anteriormente [41]. En la Fig.14 se muestra una RNN desarrollada en el tiempo.

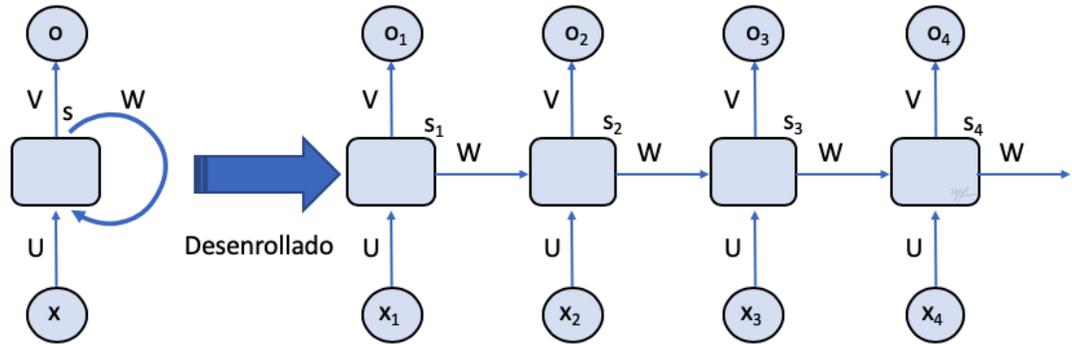


Figura 14: Red Neuronal Recurrente (RNN). Fuente : [41]

Donde el conjunto X_t se refiere a los datos de entrada a la RNN. U, V y W son matrices de pesos. O_t es el conjunto de salidas que arroja la RNN y se define como el producto del estado o estados ocultos de la RNN y la matriz V : $O_t = \phi_1(VS_t)$, donde ϕ_1 es una función de activación. S_t es un estado oculto (interno, se denomina oculto porque no es observado ni como dato, ni como salida), se define como: $S_t = \phi_2(Ux_t + WS_{t-1})$, donde ϕ_2 es una función de activación.

Sin embargo una RNN de este tipo comienza a tener problemas cuando las dependencias a largo plazo son importantes de aprender en la red neuronal. En teoría, las RNN son capaces de manejar dependencias a largo plazo. Lamentablemente en la práctica, las RNN no parecen poder aprenderlas. El problema fue explorado en profundidad por Hochreiter y Bengio; ellos encontraron algunas razones fundamentales por las cuales podría ser difícil [41]. Por esta razón, surgen las redes LSTM, las cuales añaden una cierta capacidad de 'memoria' tanto de corto como de largo plazo (Fig. 15).

Extracción de características temporales con redes LSTM.

Las capas inferiores del modelo propuesto son una red de capas LSTM. Estas capas almacenan información temporal sobre características importantes de las series temporales extraídas por la CNN. las capas LSTM conservan la memoria a largo plazo mediante el uso de unidades de memoria que pueden actualizar el estado oculto anterior. Esta funcionalidad permite comprender las relaciones temporales en una secuencia

a largo plazo. Su unidad de memoria interna y mecanismo de compuerta superan el problema de desvanecimiento del gradiente que ocurre en el entrenamiento de redes neuronales recurrentes (RNN) tradicionales. El canal de memoria y el mecanismo de compuertas (que incluye: compuerta de olvido, compuerta de entrada, compuerta de actualización y compuerta de salida) se muestran en la Fig. 15.

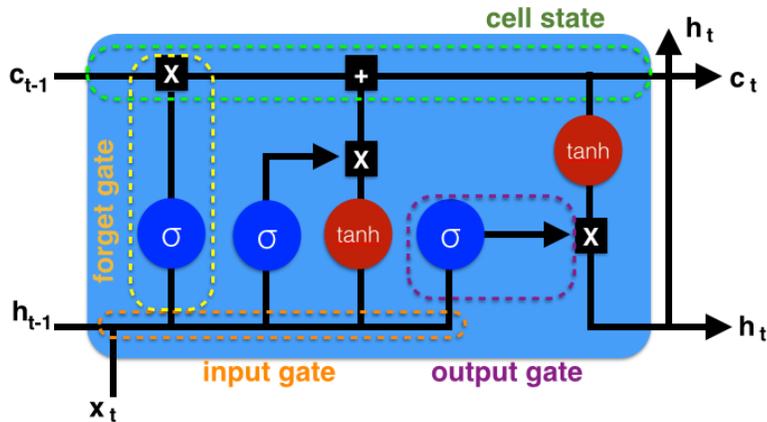


Figura 15: Célula básica de una red de tipo Long Short Term Memory (LSTM). Fuente [42]

De la Fig. 15, notamos las siguientes variables:

- X_t : es la entrada en el tiempo t .
- h_{t-1} : es la salida de la celda en tiempo $t - 1$, es decir la salida anterior.
- C_{t-1} : es la información (memoria) que es pasada por la etapa anterior.
- C_t : es la información que se transmite a la siguiente etapa.
- Las \tanh 's denotan funciones de activación, tangentes hiperbólicas.
- La operación $[[]]$ denota concatenación de las entradas.
- El operador \oplus denota suma de tensores.
- Las funciones σ son sigmoides que aproximan a una respuesta binaria (0,1). Su operación en combinación con el producto \otimes pueden entenderse como “switches” que permiten el flujo, o no, de la información [43].

Las ecuaciones que rigen el modelo LSTM son las siguientes [44]:

$$f_t = \sigma(W_f[h_{t-1}, X_t] + b_f), \quad (8)$$

f_t es la salida de la compuerta de olvido (forget gate). Y σ se refiere a la función de activación sigmoide.

$$i_t = \sigma(W_i[h_{t-1}, X_t] + b_i), \quad (9)$$

i_t es la salida de la compuerta de entrada (input gate).

$$g_t = \tanh(W_g[h_{t-1}, X_t] + b_g), \quad (10)$$

g_t es la salida de la compuerta de actualización (update gate).

$$c_t = f_t * c_{t-1} + i_t * g_t, \quad (11)$$

c_t se refiere a la celda de memoria.

$$o_t = \sigma(W_o[h_{t-1}, X_t] + b_o), \quad (12)$$

o_t es la salida de la compuerta output (output gate)

$$h_t = o_t * \tanh(c_t). \quad (13)$$

Donde h_t es un vector de salida de la celda de memoria en el tiempo t (vea la Fig.15). $W_{f,i,g,o}$ son las matrices de pesos y $b_{f,i,g,o}$ los vectores del bias.

La “memoria de largo plazo” permite que la información pase desde C_{t-1} a C_t . La memoria del canal se define como la suma de información de en la memoria C_{t-1} que deseamos preservar y la información nueva q_t que deseamos agregar al la memoria [42].

$$C_t = r_t * C_{t-1} + s_t * q_t,$$

r_t y s_t son switches que controlan el “olvido” de la memoria pasada y la información nueva a “recordar”. Dependiendo de los datos X_t y de la salida anterior h_{t-1} , la celda “olvidará” lo que el canal de memoria ha conservado [42].

La información q_t a agregar se obtiene a partir de procesar la entrada y la salida anterior:

$$q_t = \tanh(W_q[X_t|h_{t-q}] + b_q),$$

Entender el funcionamiento de las redes híbridas CNN-LSTM, es esencial para construir modelos computacionales para predicciones certeras [45], con las que construiremos los itinerarios de carga y descarga, como se verá en los próximos capítulos.

Métricas para evaluar el modelo

A lo largo de este trabajo, estaremos haciendo diferentes predicciones o inferencias con los modelos de redes neuronales, para tener una medida de evaluación para dichas predicciones, seleccionamos algunas métricas bastante conocidas. Éstas son: MSE (error cuadrático medio), RMSE (raíz del error cuadrático medio) y MAE (error absoluto medio). Estas métricas se definen de la siguiente manera:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (15)$$

$$MAE = \frac{\sum_{i=1}^n |\hat{Y}_i - Y_i|}{n} \quad (16)$$

Donde Y_i se refiere al conjunto de valores reales, \hat{Y}_i el conjunto de los valores pronosticados con el modelo y n el número total de muestras.

Predicciones

En general, existen tres métodos principales de predicción: modelos estadísticos, modelos físicos y modelos de aprendizaje máquina (Machine Learning). El modelo físico se basa en la dinámica entre los fenómenos estudiados y las leyes físicas [46]. El modelo estadístico depende principalmente de datos históricos, estadísticos y teoría de probabilidad para pronosticar series temporales futuras [47, 48]. Los modelos de aprendizaje máquina mapean directamente desde las entradas a las salidas, extraen características no lineales complejas de una manera muy eficiente [49, 43]. En los modelos de aprendizaje automático podemos destacar las redes neuronales artificiales (ANN), especialmente un tipo de ANN. Redes neuronales recurrentes (RNN), que es uno de los métodos más utilizados para pronosticar series temporales [50, 51]. La RNN ha sido estudiada en diversas aplicaciones como la predicción de la velocidad del viento [52], la predicción del consumo de energía [53, 54, 55] o incluso la predicción del tráfico [56], consiguiendo excelentes resultados.

Sin embargo, un problema común en las RNN, con métodos de aprendizaje basados en

gradientes y el algoritmo de retropropagación (backpropagation), es el desvanecimiento del gradiente. El desvanecimiento del gradiente se produce durante el entrenamiento de secuencias muy largas de datos. Esto significa que el gradiente de la función de pérdida se aproxima a cero, lo que dificulta el entrenamiento de la red [57]. Las redes de memoria a largo plazo (LSTM) resuelven este problema [58, 59, 44, 54].

Por otro lado, las predicciones en variables relevantes para los sistemas que usan fuentes renovables de energía., como la predicción PVPG y WPG, han sido estudiadas utilizando modelos LSTM por muchos autores [10, 60, 51, 57, 49] reduciendo considerablemente el error de predicción en comparación con otros métodos tradicionales.

En los últimos años, muchos investigadores han combinado modelos CNN y LSTM para extraer características temporales y espaciales [61, 39, 62]. En el campo de la medicina, por ejemplo, Gill et. al propusieron un modelo CNN-LSTM para detectar con precisión arritmias en electrocardiogramas [50]. Para la predicción de la demanda eléctrica, algunos autores [36, 32, 63] propusieron un modelo híbrido CNN-LSTM para el consumo de energía eléctrica que logró resultados superiores a otros métodos basados en el aprendizaje profundo. Descubrieron que la descomposición de series temporales con modelos de aprendizaje profundo proporciona visualizaciones útiles para comprender mejor el problema de predecir y analizar el consumo de energía [36].

Wang et. al propusieron un modelo híbrido LSTM-CNN para la predicción de PVPG [37]. Introdujeron un modelo híbrido de una dimensión para la predicción de PV. En 2020, otros autores [40, 64] propusieron un modelo híbrido CNN-LSTM similar con una arquitectura multicapa más sólida, que incluye un modelo 5D-CNN (cinco capas convolucionales) con agrupación máxima (max-pooling) y un modelo 5D-LSTM. Como es de esperarse, el modelo CNN-LSTM de cinco dimensiones consume más recursos computacionales para el entrenamiento que un modelo unidimensional, pero se logró una alta precisión [40, 64]. Otros autores con técnicas similares de aprendizaje automático han logrado excelentes resultados [65, 66, 67], debemos señalar que este trabajo no es una comparación entre otras técnicas de aprendizaje automático, sino con una marca de referencia (benchmark) bien conocida (ARIMA).

Sistemas BESS y la técnica de Rasurado de Picos

En esta sección presentaremos el estado del arte de las tecnologías BESS y la implicación del uso de estos sistemas para la reducción de picos en el área estudiada.

Los sistemas de almacenamiento de energía eléctrica (EESS) a menudo se asocian total y exclusivamente con el intercambio de energía, por ejemplo, el pareo de la generación con el consumo eléctrico, como su función única o principal en la red eléctrica. Sin embargo, estos sistemas no se limitan sólo a esa aplicación, también pueden proporcionar una amplia variedad de funciones estables, confiables y económicas a la red eléctrica [3, 4]. Los EESS se pueden dividir por su tecnología de almacenamiento, como se muestra en el Cuadro 1.

Cuadro 1: Descripción general de algunos EESS [68][3] [4]

Almacenamiento	Ejemplos de medios de almacenaje de energía
Eléctrico	Super-capacitores e inductores
Mecánico	Volantes de inercia, Sistemas de almacenamiento con aire comprimido (CAES), Reservorios de energía potencial hidráulica
Térmico	Materiales con cambio de fase y Almacenamiento de energía termoquímica
Electro-mecánico	Baterías Redox-Flow, baterías de ácido-plomo o baterías de iones de litio

Muchos artículos que muestran el estado del arte de EESS, comparan la eficiencia de diferentes tipos de unidades de almacenamiento [68], en el caso de las unidades de almacenamiento electroquímico, comparan la eficiencia de diferentes materiales [9]. En este trabajo idealizaremos un sistema de este tipo (BESS), debido a que el estado del arte muestra un mejor desempeño de esta tecnología electroquímica en comparación con el almacenamiento mecánico o térmico [68, 3]. También enfatizamos la necesidad de incorporar técnicas de aprendizaje automático basadas en datos, para Tener una gestión energética precisa de las fuentes de energía intermitentes en los sistemas de almacenamiento BESS. En otras palabras, las técnicas de aprendizaje automático, especialmente los modelos de redes neuronales híbridas, pueden dar predicciones precisas [60, 69, 4], para decidir cuándo cuándo es mejor cargar y cuándo es óptimo descargar dicha energía.

Por otro lado, propondremos un método de rasurado de picos para un caso particular de estudio: Los Cabos San Lucas en Baja California Sur (LCSN-BCS). Como expondremos en la segunda sección de este capítulo, la red eléctrica de BCS cuenta con varios generadores de combustóleo (turbogas). Los cuales, muchas veces se utilizan par el pareo de generación con consumo de energía eléctrica en las horas de mayor demanda, pero son altamente contaminantes y costosos [29]. Si pudiéramos utilizar fuentes más limpias como la solar o la eólica, repercutiría directamente en la contaminación por el uso de estos generadores contaminantes.

Por lo tanto, la capacidad de control de un BESS proporcionará una mayor flexibilidad al sistema BCS. Sin embargo, para interactuar dinámicamente con la red y mejorar la coordinación, lo que conducirá a la reducción de la demanda máxima y al ahorro de energía, es necesario integrar nuevas tecnologías como dispositivos inteligentes, comunicaciones bidireccionales y gestión integrada [1, 70, 71].

Capítulo II - Desarrollo

Caso de Estudio: Temixco, predicción de PVPG

Como ya se introdujo en el primer capítulo, la evolución del aprendizaje profundo también ha abierto la posibilidad de aplicar modelos de redes neuronales para predicción de series temporales, consiguiendo excelentes resultados [72]. En este caso de estudio, propondremos un modelo CNN-LSTM de cinco capas para predicciones de energía fotovoltaica, utilizando datos reales de una ubicación en Temixco, Morelos en México. En el modelo híbrido propuesto, la capa convolucional actúa como un filtro, extrayendo características locales de los datos y la red de memoria a largo y corto plazo LSTM, se encargan de extraer las características temporales del fenómeno de generación fotovoltaica en Temixco, Morelos.

Finalmente, el efecto predictivo del modelo híbrido de cinco capas se compara con un modelo uni-capas (una sola capa LSTM) y un modelo híbrido CNN-LSTM bi-capas. Los resultados también muestran que el modelo de red neuronal híbrida tiene un mejor efecto de predicción que el modelo híbrido bi-capas o un modelo uni-capas.

Recurso solar en Temixco-Morelos

Utilizamos datos de un sistema solar fotovoltaico (PVSS) de 1,7 [kW] y de una estación meteorológica [72] (la estación ESOLMET (Fig. 16)), en el IER-UNAM (Instituto de Energías Renovables) en Temixco, Morelos, México. Latitud: $1850'25,62''N$, longitud: $9914'10,49''W$ a 1253 [mts] sobre el nivel del mar.

Las variables eléctricas medidas desde el PVSS después del inversor son las siguientes: potencia activa generado [W], la corriente de fase promedio generada [A] y el voltaje

de CA generado [V]. las variables disponibles por la ESOLMET son: radiación directa [W/m^2], radiación global [W/m^2], radiación difusa [W/m^2], temperatura [C], humedad [%], velocidad del viento [m/s] y presión barométrica [mBar]. Todas estas diez variables conformarán nuestro conjunto de datos para el entrenamiento del modelo, ver Fig. 17 [72].



Figura 16: Estación meteorológica ESOLMET, IER, Temixco, Morelos [72]

El conjunto de datos consta de 52 428 valores por variable. Desde la fecha: 01/01/2019 00:00:00:00 hasta la fecha: 01/01/2020 00:00:00:00. Con una resolución de 10 minutos. Estas diferentes variables son procesadas por la red neuronal híbrida (Fig.18), como se mencionó en los capítulos anteriores, la parte LSTM extrae la parte temporal, en el caso de generación fotovoltaica, al ser esta un fenómeno intermitente, la red LSTM aprende fácilmente su temporalidad. Por otro lado las capas CNN aprenderán la forma de esa curva, que proviene de características espaciales propias del lugar, como la radiación solar, temperatura, etc.

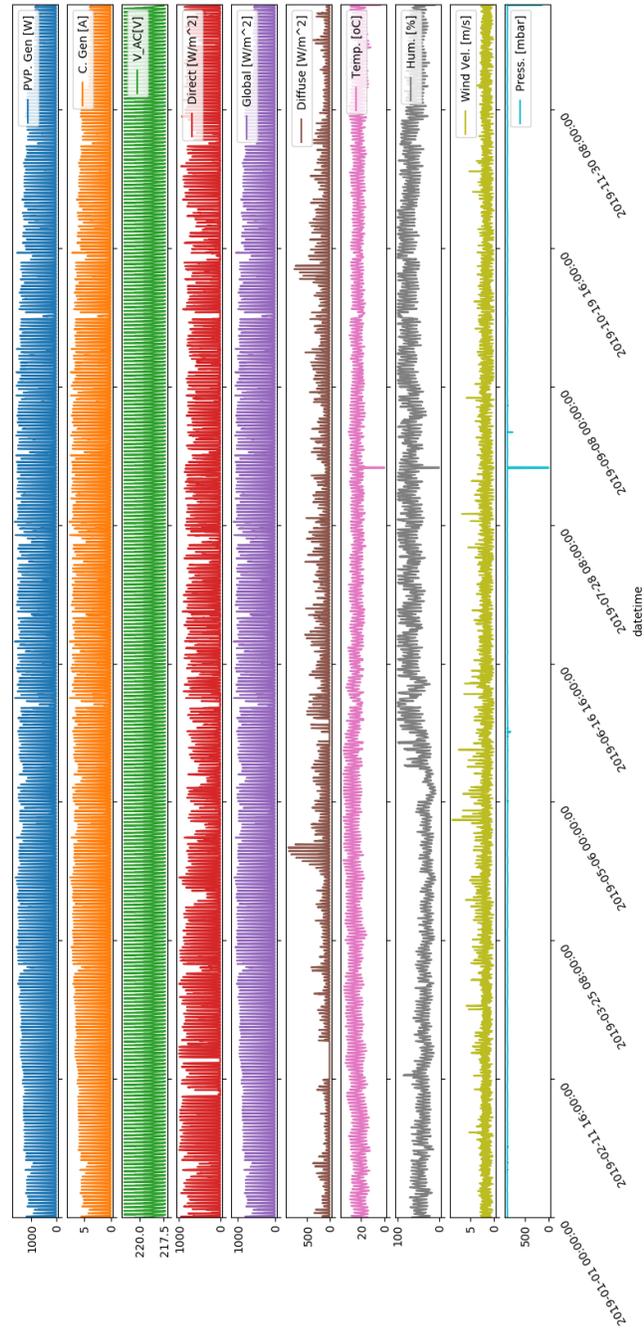


Figura 17: ESOLMET Dataset, IER, Temixco, 2019. [72]

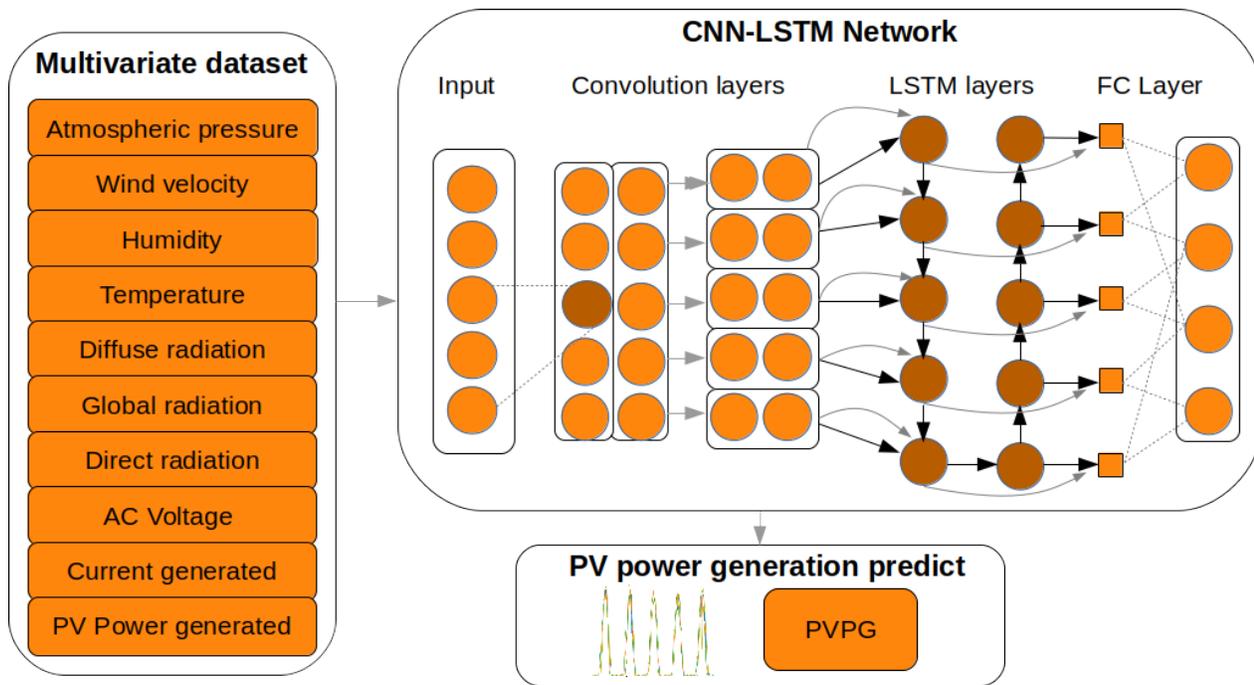


Figura 18: Modelo CNN-LSTM para predicción de potencia fotovoltaica.

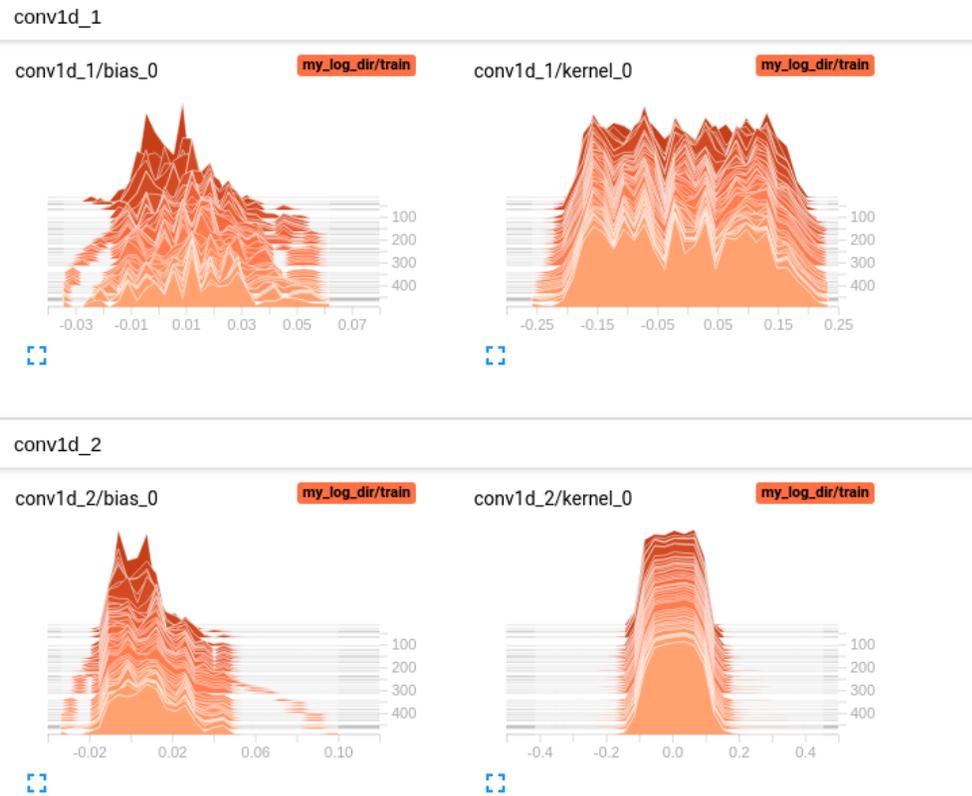


Figura 19: Capas convolucionales extrayendo características del fenómeno local.[73]

Finalmente se hicieron predicciones de generación fotovoltaica de 5 días en adelante, comparando un modelo híbrido con 5 capas (curva amarilla), un modelo híbrido bi-capas (curva naranja) y un modelo uni-capas LSTM (curva verde). Se escogieron diferentes estaciones del año para verificar el efecto predictivo del modelo a lo largo del año (Figs. 20 -23).

Como se puede apreciar las métricas del desempeño del modelo propuesto en el Cuadro 2, se puede apreciar que el modelo con 5 capas tiene un error aproximadamente 10 veces menor que el modelo uni-capas LSTM, cabe de esperarse que esta precisión viene acompañado de un alto tiempo de procesamiento (5 veces más que el tiempo de procesamiento del modelo uni-capas véase Cuadro 3).

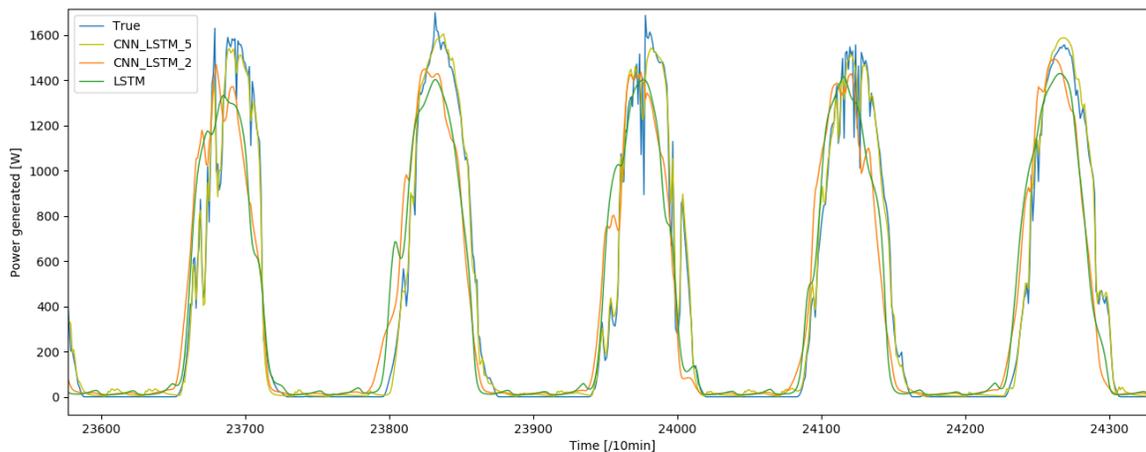


Figura 20: Predicción de generación FV durante el verano.

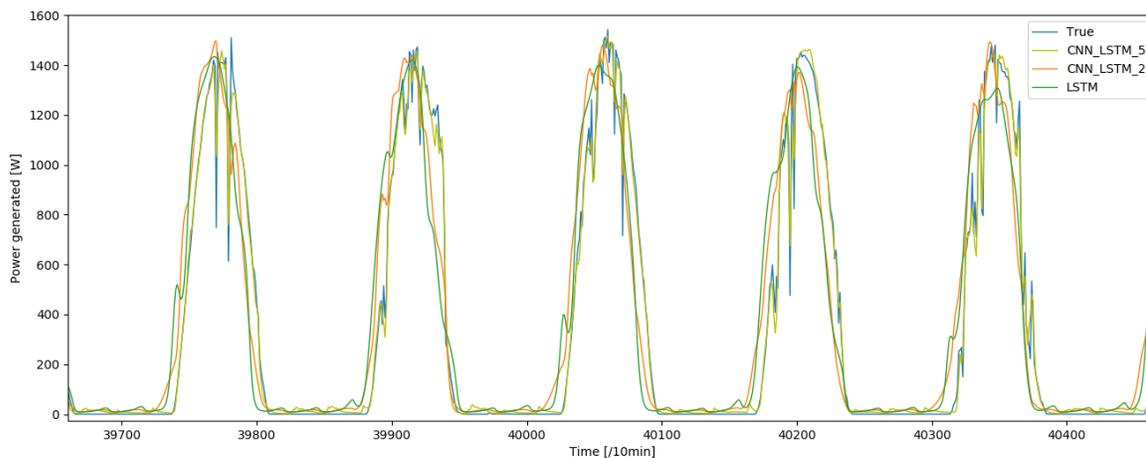


Figura 21: Predicción de generación FV durante el otoño.

Cabe recalcar que el efecto predictivo del modelo propuesto es formidable² incluso en días lluviosos donde la variabilidad del recurso es alta (Fig.23). Este caso de estudio es importante ya que la precisión de estas predicciones servirán para proponer un sistema de almacenamiento 'inteligente' con itinerarios de carga y descarga en los próximos capítulos.

²Véase las métricas en el Cuadro 2 para entender de manera cuantificable el adjetivo formidable.

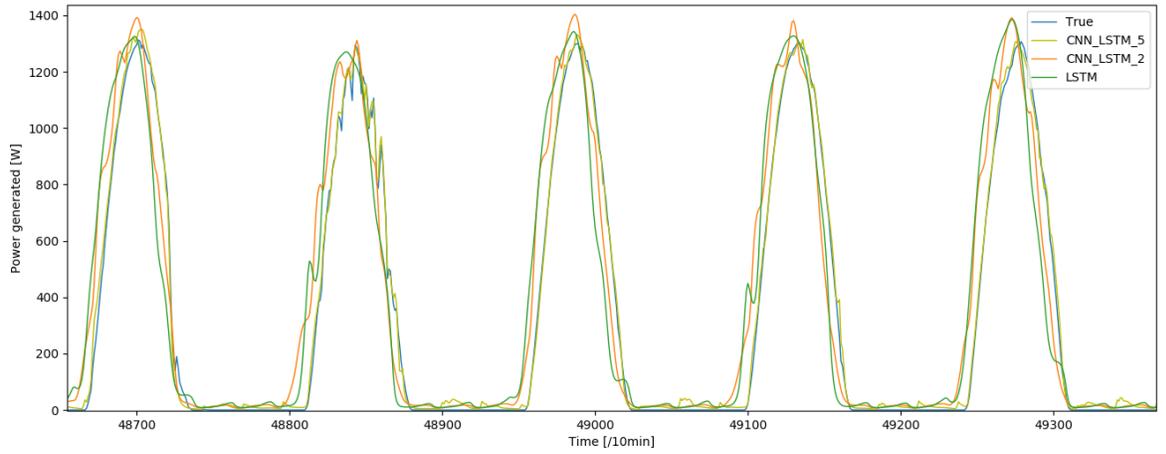


Figura 22: Predicción de generación PVPG durante el invierno.

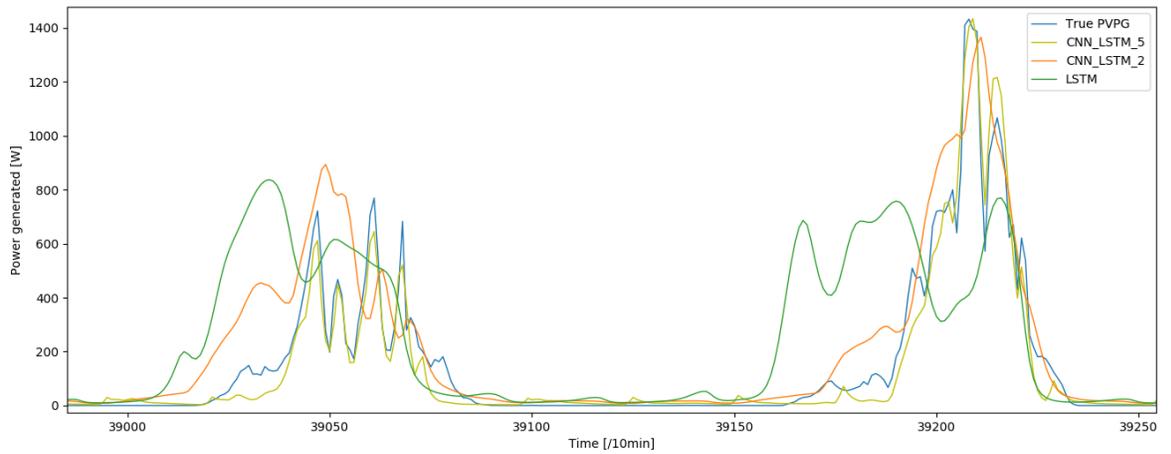


Figura 23: Predicción de generación PVPG durante temporada de lluvias.

Cuadro 2: Métricas para evaluar la predicción del modelo propuesto

Modelo	MSE	RMSE	MAE
LSTM 5	0.0854788623	0.2923676835	0.1666727318
CNN LSTM 2	0.059041463	0.242984493	0.1410550836
CNN LSTM 5	0.006897012	0.083048253	0.1666727318

Cuadro 3: Tiempo de procesamiento por cada época.

Modelo	Tiempo [s]
LSTM 5	5.1394
CNN LSTM 2	8.0362
CNN LSTM 5	19.1148

Caso de Estudio: Itinerarios de carga y descarga en Reino Unido

En este capítulo se presenta brevemente el caso de estudio de una locación en el Reino Unido (Fig 24), con datos de libre acceso disponibles en [74]. El objetivo en este caso de estudio consistió en dos partes. Primero hacer un modelo que pudiera correlacionar varias variables climatológicas (Fig 25) para hacer predicciones de generación PV. La segunda parte consistía en proponer horarios para cargar y descargar la energía de un sistema de baterías (Fig.26), ayudados de dichas predicciones priorizamos la carga con el recurso solar. Para la parte de la descarga se hizo un proceso similar, se nos dieron series temporales de la demanda y tuvimos que generar modelos que pudieran predecir para un día en adelante, la demanda eléctrica y diseñar los horarios de descarga con el objetivo de aplanar los picos de dicha demanda.

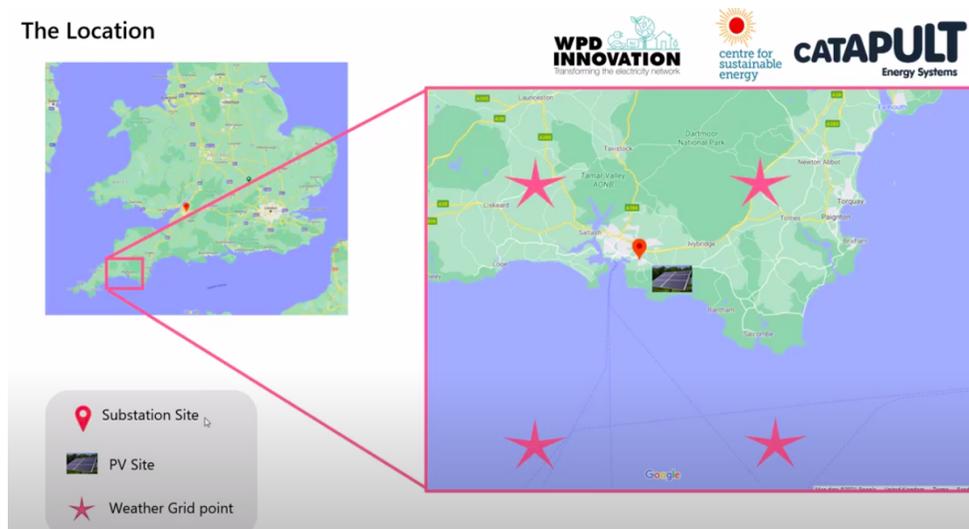


Figura 24: Locación de las diferentes centrales meteorológicas y una central PV en el Reino Unido [74].

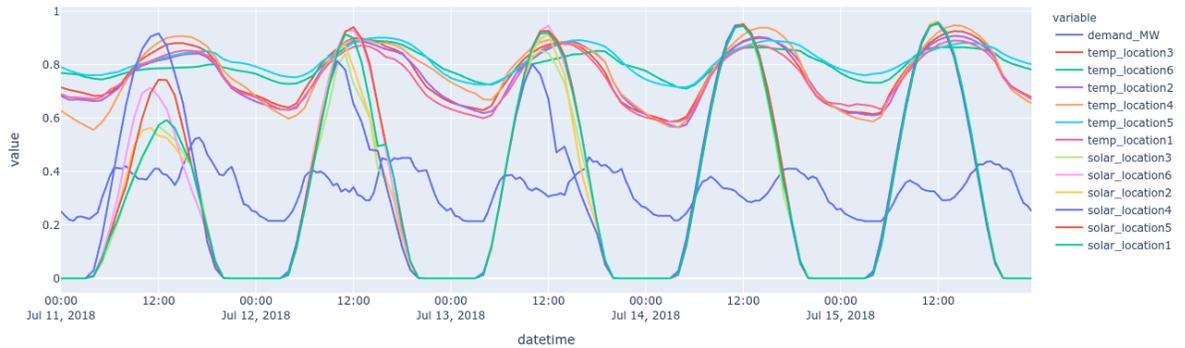


Figura 25: Variables climáticas de las diferentes estaciones meteorológicas.

Es en este caso de estudio donde se introduce un elemento más, el sistema de almacenamiento, en el caso de estudio pasado, se tenía como elemento principal una unidad generadora PV. El BESS nos permitió entender de mejor manera la administración de la energía, además que en un contexto de micro-redes y transacciones energéticas, el BESS es sin dudas un elemento indispensable [9]. El funcionamiento de este modelo de BESS ideal, se describirá a detalle en el próximo capítulo.

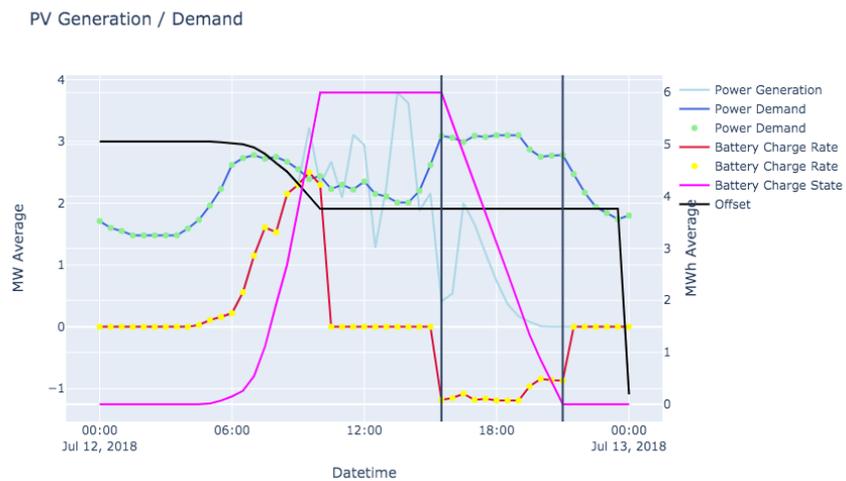


Figura 26: Modelo de sistema de almacenamiento ideal con baterías para carga y descarga.

Finalmente este caso de estudio, permitió darnos cuenta de una aplicación inmediata de las predicciones con modelos de aprendizaje automático, es decir saber cuándo y cuánto cargar (priorizando la carga con energía solar en este caso) y de la misma

manera saber cuánto y cuándo descargar este sistema de almacenamiento propuesto (priorizando un rasurado de picos en la demanda local) (Fig.27). Este concepto es a lo que llamamos itinerarios de carga y descarga. Esta experiencia fue esencial para abordar los siguientes casos de estudio en BCS, México. Donde se incluirán además de un generador PV con su BESS asociado, se incluye un elemento de generación eólica (como se verá en el próximo capítulo la región de BCS es privilegiada en cuanto a recurso solar y eólico se refiere), pudiendo de esta manera atender dos BESS capaces de aplanar múltiples picos de la demanda local de BCS.



Figura 27: Demanda y tasa de descarga de la batería.

Modelo para el sistema de almacenamiento basado en un sistema de baterías ideales (BESS)

El objetivo del modelo para el sistema de almacenamiento (BESS), es maximizar el porcentaje de energía almacenada proveniente de fuentes renovables por la mañana y por la tarde, en los alimentadores de distribución primario y secundario para cada día durante un período de cinco días, mientras se utiliza la mayor cantidad posible de PVPG o WPG para lograrlo.

Esto se logra encontrando un perfil de carga apropiado para el dispositivo de almacenamiento, de modo que se cargue a la tasa correcta durante los períodos diurnos (o nocturnos) cuando hay mucha generación solar o eólica, y se descargue a la tasa correcta durante cierto período en el mañana o por la tarde. Esto se hace de la siguiente manera. En primer lugar, el dispositivo de almacenamiento de batería está limitado por la tasa máxima de importación y mínima de exportación de carga y descarga, respectivamente.

$$B_{min} \leq B_{d,k} \leq B_{max}. \quad (17)$$

Para efectos de este trabajo, la tasa máxima de carga es de $B_{max} = 500$ [kW] y la tasa de descarga máxima es de $B_{min} = -500$ [kW]. En segundo lugar, la batería no puede cargar más allá de su capacidad. Sea $C_{d,k}$ la carga total (en KWh) de la batería en el día d y hora k .

$$0 \leq C_{d,k} \leq C_{max}. \quad (18)$$

Donde la capacidad máxima para este trabajo es $C_{max} = 50[KWh]$. El cambio en la carga total de la batería de un paso al siguiente está relacionado por:

$$C_{d,k+1} = C_{d,k} + 0,5B_{d,k}. \quad (19)$$

El otro objetivo del BESS es maximizar la cantidad de PVPG o WPG. En otras palabras, cuando $B_{d,k} > 0$, (es decir, al importar energía), la función de carga se puede escribir como:

$$B_{d,k} = P_{d,k} + G_{d,k}. \quad (20)$$

Donde $P_{d,k}$ es la energía promedio almacenada en la batería proveniente de una fuente renovable y $G_{d,k}$ es la energía almacenada proveniente de la red en la hora k .

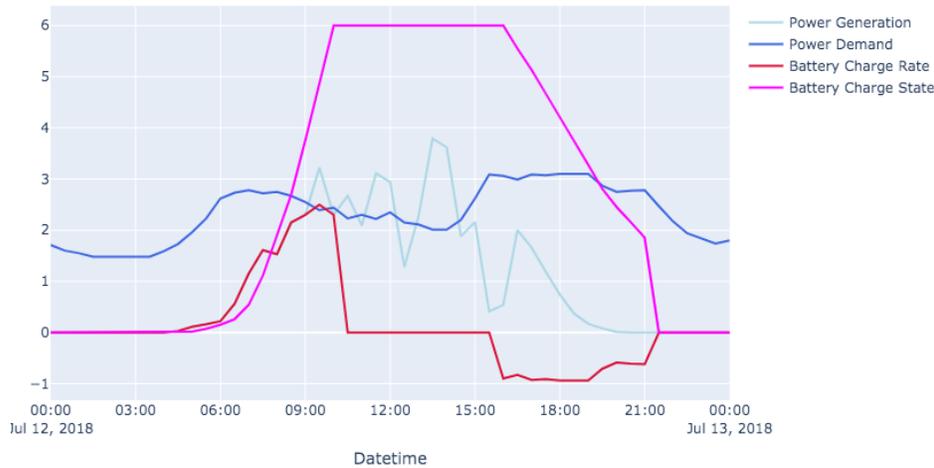


Figura 28: BESS ideal cargándose con PVPG [75].

Si la capacidad restante del BESS ($C_{d,k}$) es menor que la tasa de descarga mínima durante la carga máxima, el sistema descargará la capacidad restante total.

Finalmente, el rendimiento del modelo BESS ideal propuesto con PVPG se muestra en la Fig.28, se espera que la tasa de carga comience a aumentar con la generación fotovoltaica y comience a disminuir (descargarse) durante la ventana de tiempo seleccionada dadas las tarifas de CFE de gran demanda en media tensión durante la tarde.

Para la legislación mexicana [30], se considera generación distribuida cuando la potencia del sistema generada es menor a 500 [kW], para más de 500 [kW], se debe considerar el precio marginal local (PML) en la estrategia de carga y descarga de baterías.

Caso de Estudio: Itinerarios en LCSN-BCS

Recurso solar en LCSN-BCS

En esta sección, utilizaremos datos meteorológicos para estimar el recurso solar en el área de BCS y posteriormente simular una planta de PVPG. Para ayudarnos en este proceso, utilizaremos el software de licencia gratuita: System Advisor Model (SAM) de NREL [76, 77].

El perfil de irradiancia a lo largo de 365 días en BCS, en la localidad de estudio (abajo se muestra la latitud y longitud), que corresponde a la ciudad de Los Cabo San Lucas,³ se muestra en la Fig. 29 (serie temporal de irradiancia completa). Como se puede observar, los meses de marzo, abril y mayo son los meses donde hay un valor de irradiancia mucho mayor. En contraparte, los menores valores de irradiancia se dan en los meses de diciembre y enero. Tenga en cuenta que la variación puede ir desde $200[W/m^2]$ hasta valores máximos de $1100[W/m^2]$, esta es una de las grandes desventajas y desafíos de la energía solar, la naturaleza intermitente de la energía solar.

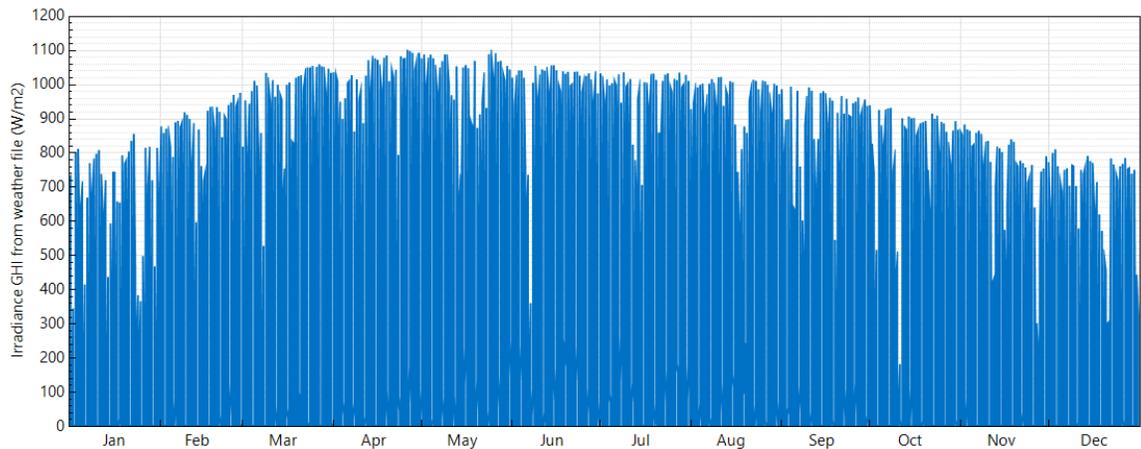


Figura 29: Irradiancia global en BCS durante el 2018 [76, 77].

³LATITUD = 22.972185, LONGITUD = -109.667267.

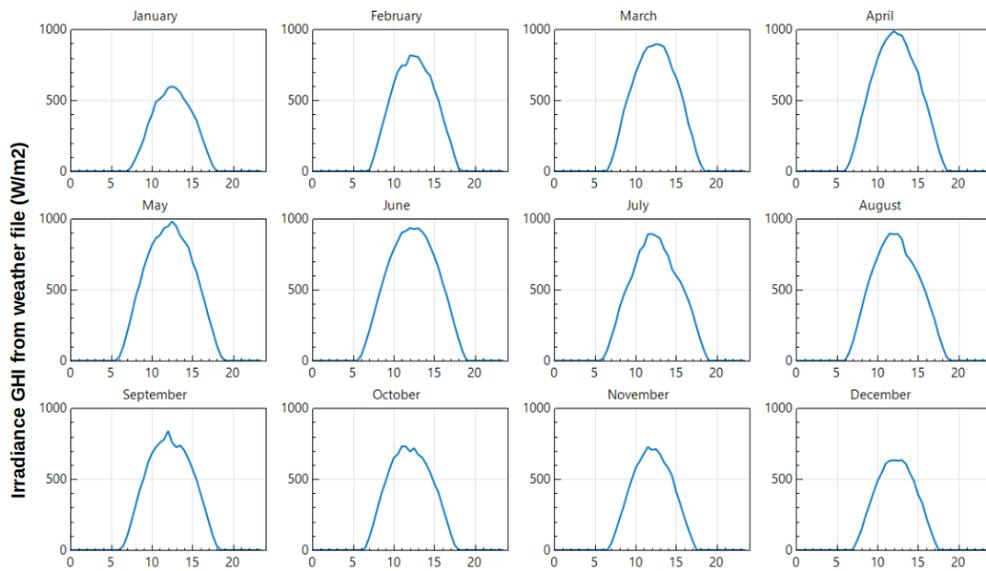


Figura 30: Perfiles mensuales de irradiancia promedio en BCS [76, 77].

La Fig. 30 muestra los perfiles de irradiancia promedio por mes durante 24 horas. En esta imagen se muestra claramente que los meses con el recurso solar mínimo en el área de estudio son enero y diciembre. En su mayoría, durante todo el año hay presencia de recurso solar de las 6:00 a 18:00 hrs., teniendo los valores máximos de irradiancia de las 10:00 a 15:00 hrs., (Fig.30).

Recurso eólico en LCSN-BCS

Al igual que hicimos con el recurso solar en la sección anterior, usaremos SAM y los archivos de datos de velocidades de viento correspondientes a las coordenadas de Los Cabos San Lucas, para simular una planta de generación eólica (Fig.33). Como podemos ver en las Figs. 31 y 32, el recurso eólico es abundante en la región durante todo el año. Sin embargo, la naturaleza volátil del recurso eólico es considerablemente grande. Como podemos observar en la Fig.31, la velocidad del viento puede variar entre $0 - 18[m/s]$.

Las especificaciones del aerogenerador utilizado son: Aerogenerador ElectriaWind Garbi 140 [kW] (fabricante), altura 80 mts, coeficiente de cortante = 0,13. En la Fig.33 podemos destacar que la velocidad de corte de viento es de $2[m/s]$ y la velocidad de corte de viento de la turbina es de $14[m/s]$, aprovechando en buena medida esta fuente variante. En la Fig. 32 se muestra la velocidad promedio del viento por mes. Podemos destacar que mayoritariamente hay abundante recurso eólico en horas nocturnas y un importante descenso de 10:00 a 15:00 horas. Sin embargo para el caso solar, estas son las horas de alta irradiancia (Fig.30), es por esto que se propone una generación híbrida solar-eólica en el área LCSN-BCS.

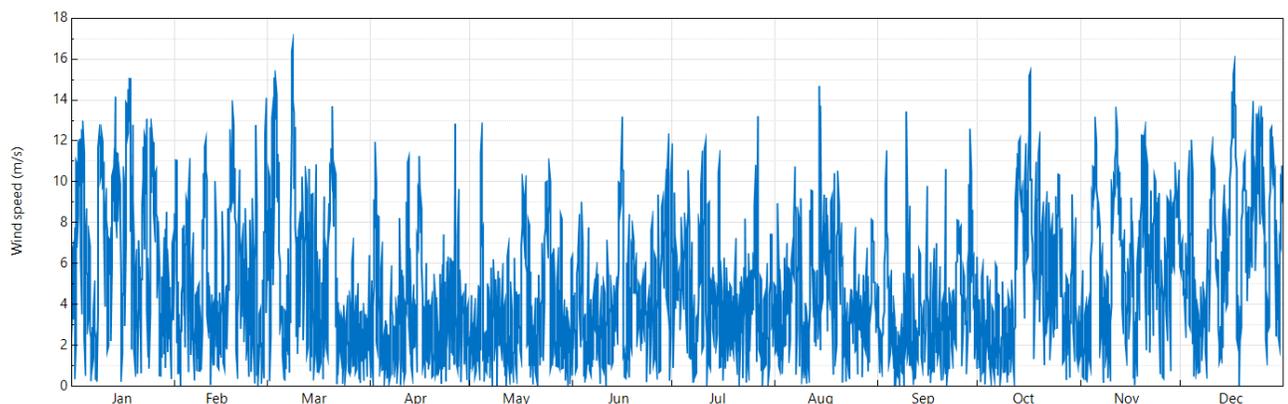


Figura 31: Perfiles de velocidades de viento en BCS [76, 77].

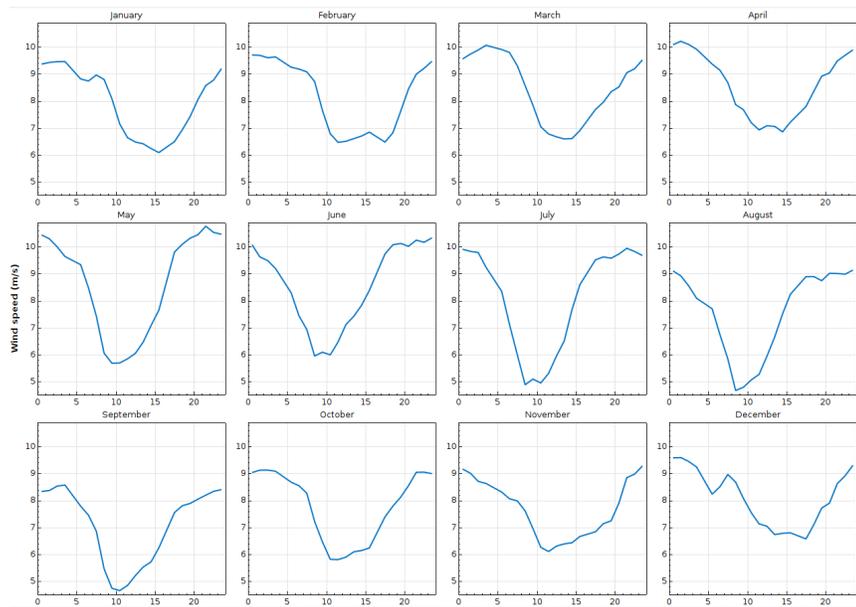


Figura 32: Perfiles promedio mensuales de velocidades de viento en BCS [76, 77].



Figura 33: Velocidad de viento (azul) y generación eólica (SPG, naranja) por una turbina de 140 kW en BCS [76, 77].

Red eléctrica de BCS

La zona BCS contiene un sistema eléctrico autónomo que está aislado de la red eléctrica nacional, tal como se muestra en el mapa de transmisión de la red nacional (Fig. 30). El sistema BCS está compuesto por dos sistemas: Mulegé (53) en la parte norte del estado, y BCS en la parte sur (50-52), donde se ubican los centros con mayor carga (La Paz, San José del Cabo y Cabo San Lucas) [6, 12]. [29, 7].

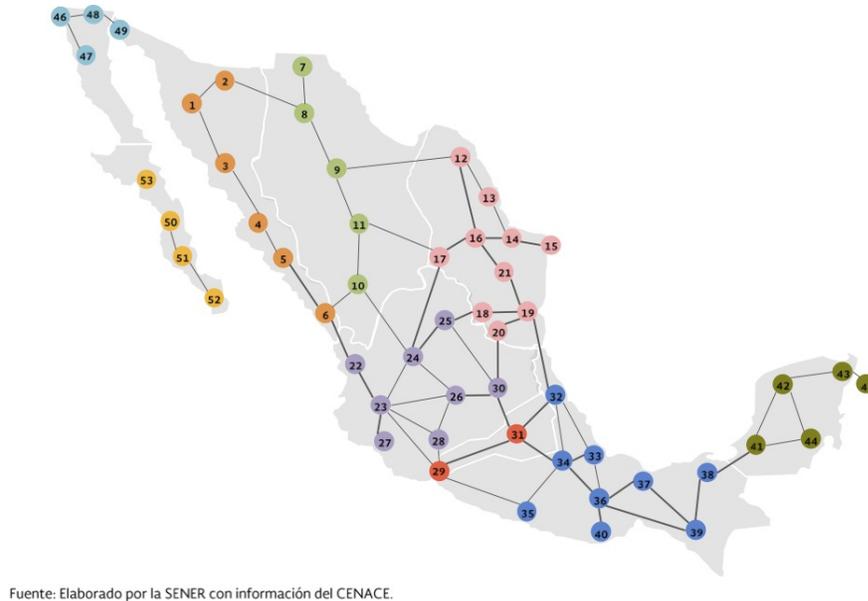


Figura 34: Sistema Eléctrico Nacional, México [29].

El sistema eléctrico de Baja California Sur se divide en tres regiones: Constitución, La Paz y Los Cabos. El mapa de la Fig. 34 muestra un esquema general de este sistema de transmisión, incluyendo las tres zonas eléctricas del sistema BCS y la ubicación de los principales centros de carga y plantas de generación. Como se puede observar en la Fig. 60, actualmente existen 28 centros de consumo, 2 plantas de combustión interna, 3 turbogas, 1 termoeléctrica, 1 ciclo combinado, 1 parque eólico y 3 plantas solares fotovoltaicas, sumando una capacidad instalada total de 883.805 MW [29].

Además, algunos estudios demuestran que la incorporación de BESS alimentado con REN puede disminuir efectivamente las centrales eléctricas de pico [15] [28], si se incorpora un buen sistema de gestión de energía [78]. La región de BCS está altamente dotada de recursos solares y eólicos [9], por lo que en este trabajo se propone una técnica novedosa basada en redes neuronales híbridas para programar itinerarios de

carga y descarga, para incorporar una gestión de energía basada en datos en una región específica de LCSN-BCS.

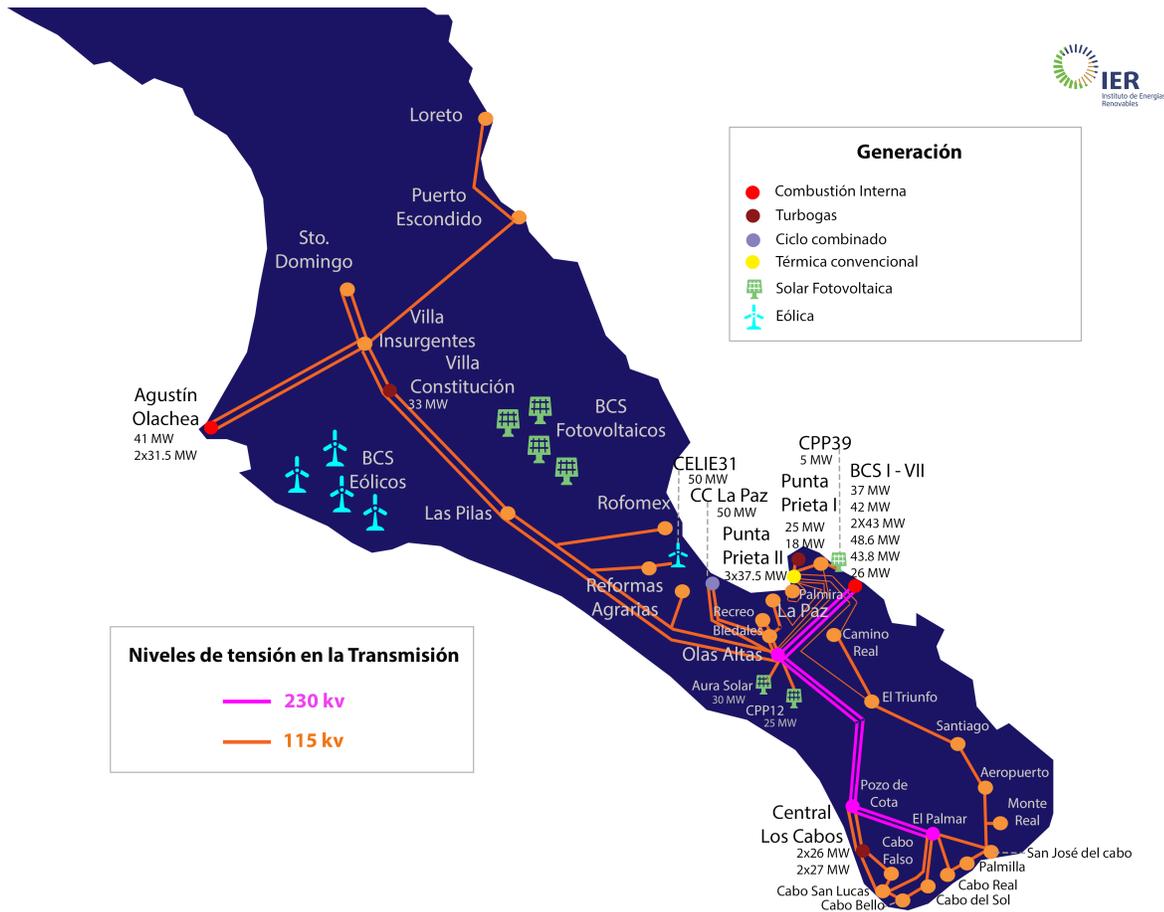


Figura 35: Sistema Eléctrico BCS [29, 7, 75].

Construcción del dataset y el modelo híbrido CNN-LSTM propuesto.

En las próximas secciones vamos a presentar los datos utilizados para entrenar el modelo híbrido propuesto. Además, del modelo CNN-LSTM en sí.

Variables climáticas en la zona de LCSN-BCS

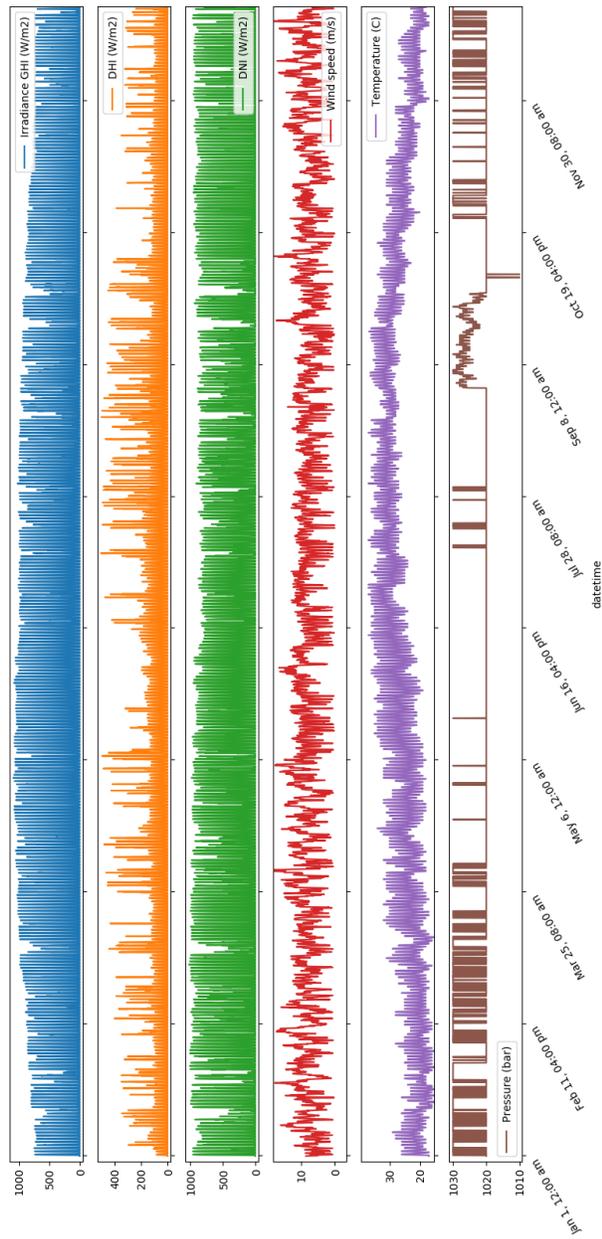


Figura 36: Variables climáticas en Los Cabos San Lucas, BCS [76, 75].

En esta sección se presentan el dataset de variables meteorológicas, en la Fig.36 se presentan las variables del conjunto de datos de NREL de la ubicación estudiada, Los Cabos San Lucas, BCS. Esto incluye seis variables medidas a lo largo de 2018 como son: Irradiación Horizontal Global (GHI en $[W/m^2]$), que está compuesta por la Irradiación Horizontal Difusa (DHI en $[W/m^2]$) y la Irradiación Normal Directa (DNI en $[W/m^2]$). También incluimos el perfil de velocidad del viento de la localidad ($[m/s]$), la temperatura ($[^{\circ}C]$) durante el año estudiado en la región y la presión atmosférica ($[mbar]$).

Series de tiempo de generación renovable y demanda eléctrica en la zona de LCSN-BCS

En esta sección vamos a introducir las variables eléctricas que se incorporaran al dataset de entrenamiento, estas son: Demanda eléctrica de LCSN en $[kW]$. Y las series de tiempo de generación: PVPG en $[kW]$ y WPG en $[kW]$ (ver Fig. 37).

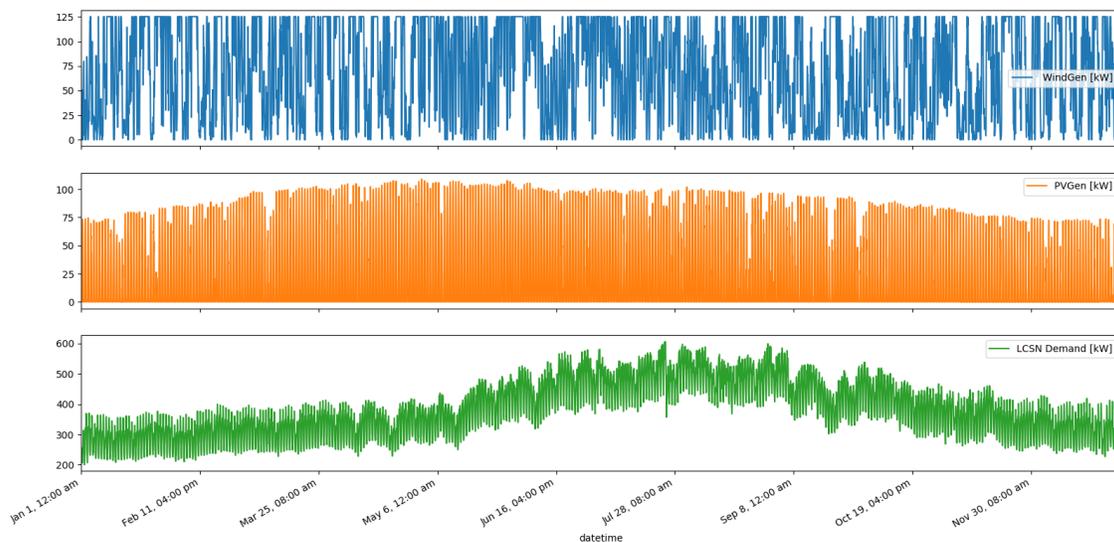


Figura 37: Generación Renovable (WindGen y PVGen) y demanda eléctrica en Los Cabos San Lucas, BCS (LCSN-BCS Demand).

Como se mencionó en el Capítulo 2, para las series de tiempo de PVPG y de WPG

usamos el software SAM[77] de NREL para simular una planta fotovoltaica de 110 [kW] y una planta de generación eólica nominal de 140 [kW] en la región de LSCN- BCS, México.

Para la demanda eléctrica (Fig. 38) usamos datos de la Comisión Federal de Electricidad en México (CFE) de cierta industria hotelera de la región. Como podemos ver, existe una tendencia notoria de estacionalidad debido a la industria del turismo en los meses de junio, julio y agosto. Asimismo, se observa que el perfil de demanda presenta dos picos, uno en periodo matutino y otro en un periodo nocturno.

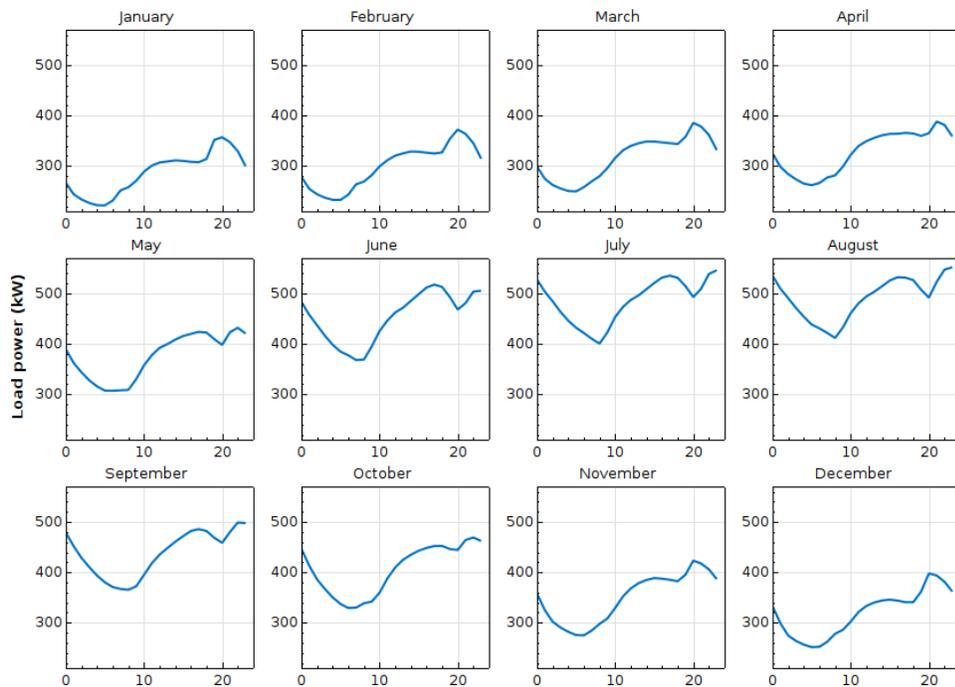


Figura 38: Perfiles de demanda promedio por mes en Los Cabos San Lucas, BCS.

Modelo híbrido CNN-LSTM

La estructura CNN-LSTM propuesta inspirada en los trabajos de [37, 36], como se muestra en el Cuadro 4, consta de una serie de capas CNN-LSTM de tres dimensiones y una capa llamada fully conectad, la cual se encarga de agrupar los datos a la salida. Por otra parte, la entrada de la red neuronal propuesta tiene diez variables, tales como temperatura, irradiancia, velocidad del viento y otras (Figs. 36 y 37).

Primero, la capa superior de CNN-LSTM consta de una red neuronal convolucional (CNN). Las capas CNN pueden recibir diversas variables que afectan a cualquier fenómeno de serie temporal. Por otro lado, el conjunto de datos se separa en dos partes: un 80 % para entrenar el modelo y un 20 % para validar los resultados.

La CNN consta de una capa de entrada que acepta variables climáticas y eléctricas como entradas, una capa de salida que extrae características las cuales después pasan a la parte temporal LSTM y varias capas ocultas. Las capas ocultas utilizadas consisten en: una capa de convolución, una capa ReLU, la cual es una función de activación que introduce las no linealidades al modelo.

A partir de los datos presentados en la entrada, se genera un patrón de salida único. La CNN extrae las características locales y la parte LSTM las temporales. Con esta estructura, la red neuronal 'aprende' para cada entrada un peso que determina una salida específica. Es así que con estas redes híbridas, finalmente se contruyen 3 modelos diferentes: Fig. 39 para predicción WPG, Fig. 40 para predicción PVPG y Fig. 41 para ED.

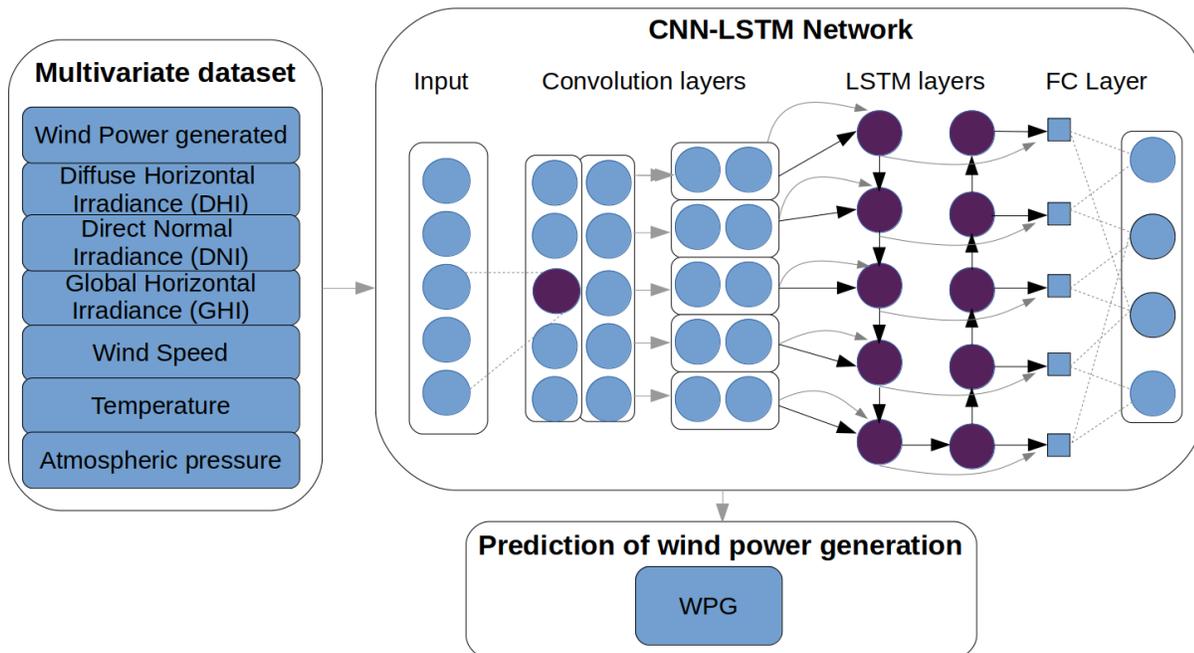


Figura 39: Estructura general para el modelo de predicción de WPG.

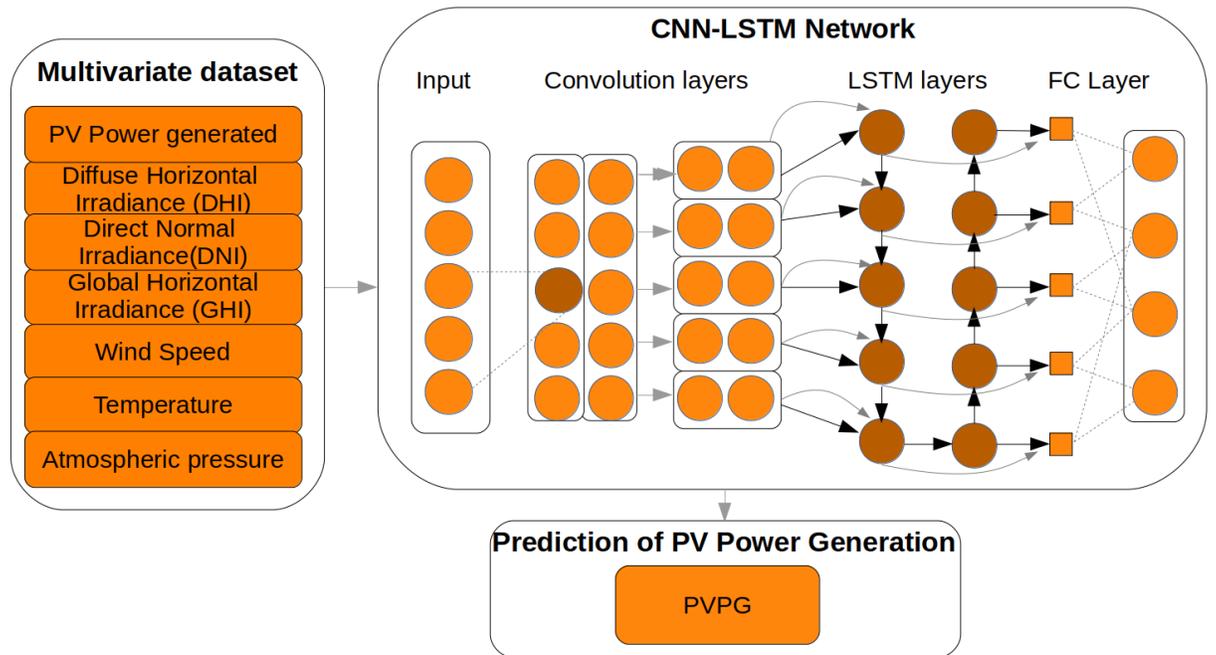


Figura 40: Estructura general para el modelo de predicción de PVPG.

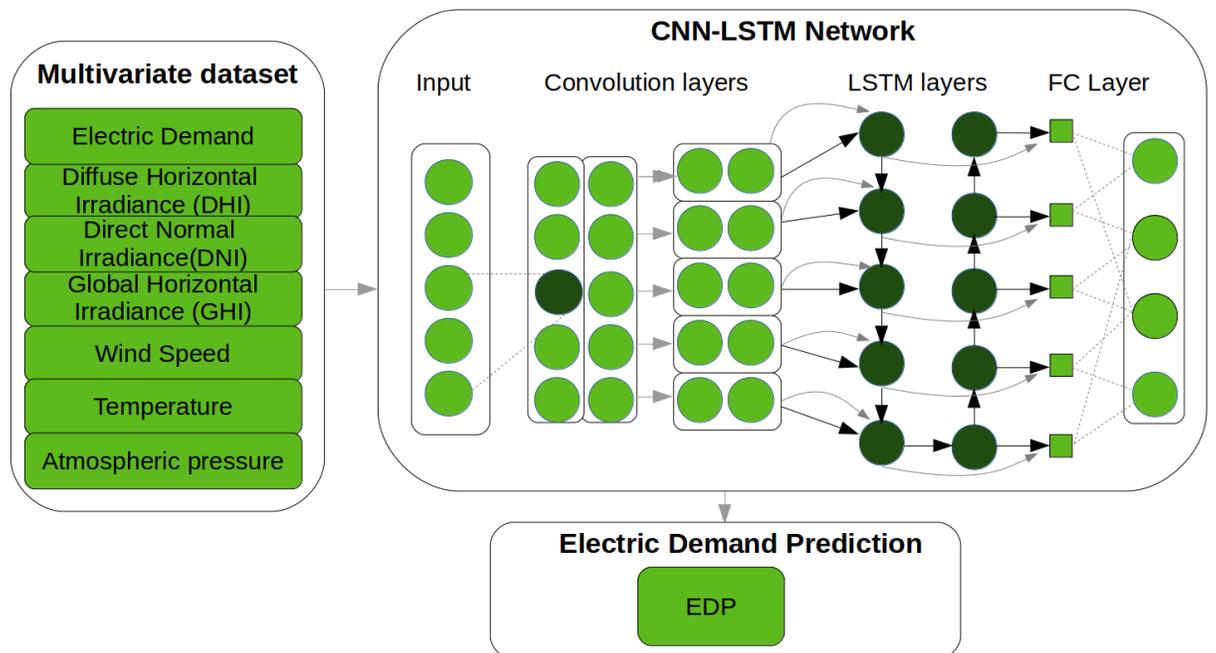


Figura 41: Estructura general para el modelo de predicción de ED.

La configuración de las capas CNN en el modelo híbrido consta principalmente de

tres capas convolucionales y tres capas de agrupación. El número de núcleos de convolución es 64, 128 y 64 respectivamente con una función de activación ReLU.

El modelo LSTM en el modelo híbrido consta de tres capas ocultas, que tienen respectivamente 64, 128 y 64 neuronas. También hay un parámetro de dropout de 0,1 para evitar el sobreajuste del modelo (conocido como overfitting) y finalmente, dos capas totalmente conectadas con 1024 neuronas cada una, las cuales agrupan los datos para su salida. Para este experimento se seleccionaron 700 épocas. En términos de redes neuronales artificiales, el parámetro de época (epoch) se refiere a un ciclo a través del conjunto de datos de entrenamiento completo. Los ajustes de parámetros específicos del modelo se muestran en el Cuadro 4, se mantienen los nombres de dichos parámetros en inglés para su fácil reproducción del modelo.

Todos los hiperparámetros fueron diseñados por el método de prueba y error. Este proceso significa que se especifican ciertos hiperparámetros, luego se entrenan con el 80 % de los datos y se validan con otro 20 %, para las cuatro estaciones del año. Luego se cambian los hiperparámetros y se repite el proceso hasta que finalmente se optimizan.

Cuadro 4: Configuración interna de las capas del modelo propuesto.

Capa	Configuración	Función de activación	
Convolution 1	filters = 64; kernel size = 3	ReLU	loss function = mse
Max-pooling 1	kernel size = 2; stride = 2		
Convolution 2	filters = 128; kernel size = 3	ReLU	optimizer= adam
Max-pooling 2	kernel size = 2; stride = 2		
Convolution 3	filters = 64; kernel size = 3	ReLU	batch size=1
Max-pooling 3	kernel size = 2; stride = 2		
LSTM 1	Units = 64	Tanh, Sigmoid	
LSTM 2	Units = 128	Tanh, Sigmoid	
LSTM 3	Units = 64	Tanh, Sigmoid	
Dropout	dropout = 0.1		
Fully connected	Neurons = 1024		

El modelo propuesto fue entrenado en una modalidad autorregresiva de varios pasos (multi-step). En una predicción de varios pasos, el modelo necesita aprender a predecir un rango de valores futuros. Por lo tanto, a diferencia de un modelo de un solo paso (single-step), donde sólo se predice un único punto futuro, un modelo de varios pasos

predice una secuencia de valores futuros. Hay dos enfoques aproximados para esto: Predicciones de disparo único, donde la serie de tiempo completa se predice a la vez. Y una predicción autorregresiva, donde el modelo solamente hace predicciones de un solo paso y su salida se retroalimenta como su entrada (Fig.42). La ventaja de este estilo de modelo es que se puede configurar para producir resultados con una longitud variable [73], es decir esta modalidad nos permite tener un horizonte de predicción variable.

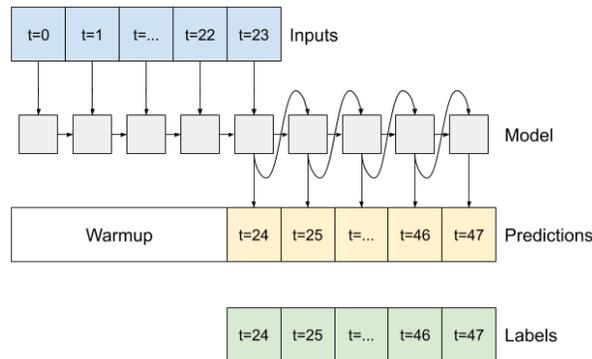


Figura 42: Predicciones mediante la técnica de Multi-step Autoregresivo [73]

Para demostrar el buen desempeño de los modelos propuestos, los resultados obtenidos por nuestros modelos se compararán con una prueba estándar reconocida (benchmark en inglés) [79], el enfoque de la media móvil integrada autorregresiva (ARIMA) [80]. Pronosticaremos la demanda de PVPG, WPG y electricidad para hacer dos itinerarios diferentes, uno para cargar durante el día (con recurso solar) y descargar durante la noche y otro para cargar durante la noche (con recurso eólico) y descargar durante la mañana. Estos resultados serán discutidos más adelante en las últimas secciones.

Capítulo III - Resultados

Proponemos una arquitectura 3D-CNN con max-pooling y otra estructura 3D-LSTM con una capa fully-connected para predecir diferentes datos de series temporales para un horizonte de cinco días. Usamos el framework Keras y Tensorflow en Python3.6 para programar los modelos. El proceso computacional se realizó en una GPU de propósito general, de la serie NVIDIA Maxwell de 128 núcleos, y una CPU Quad-core ARM A57 (1.43 GHz).

Predicciones para la demanda eléctrica.

Como podemos ver en la Fig.43, el modelo sigue la tendencia de la curva de demanda durante el entrenamiento, sin un comportamiento extraño como ajuste insuficiente (under-fitting) o sobre ajuste (over-fitting). En la Fig.45 se muestra la predicción de la demanda eléctrica para los próximos cinco días. Estas predicciones de ED ayudarán a construir la ventana de tiempo de descarga para los itinerarios en la sección 5.4.

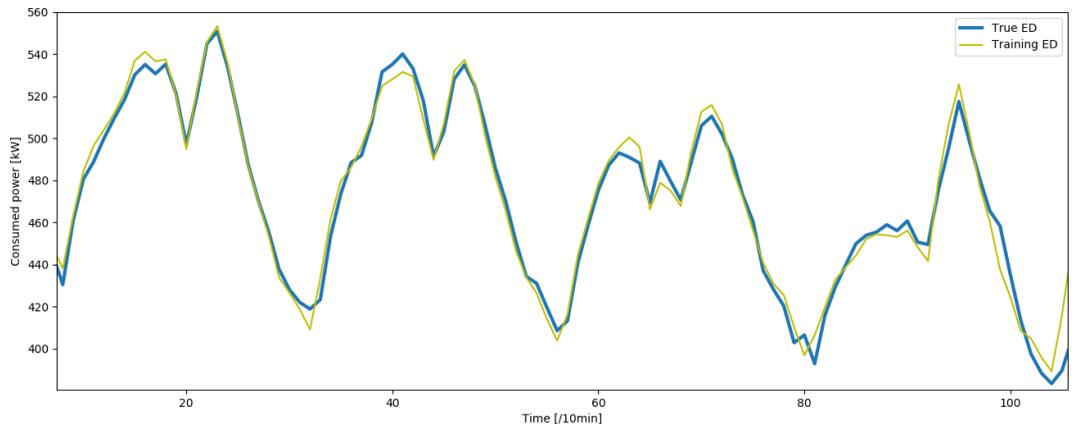


Figura 43: Entrenamiento del modelo CNN-LSTM para la demanda eléctrica.

En la Fig. 44, la curva azul representa la demanda real, la roja, la predicción de demanda eléctrica con el modelo híbrido CNN-LSTM propuesto y la amarilla la predicción de ED con el enfoque ARIMA. Como podemos ver para este caso, el enfoque ARIMA subestima la demanda mientras que el modelo CNN-LSTM predice efectivamente la curva de demanda eléctrica. Cabe señalar que el modelo propuesto también subestima esta variable en algunos momentos; sin embargo, este error es mucho menor que el enfoque ARIMA. Podemos observar que la parte temporal es muy exacta y predice efectivamente los dos picos. En base a esta información, programaremos un horario de descarga para los itinerarios del apartado 5.4 de 6:00 a 13:00 horas (punta de la mañana) y otro de 22:00 a 5:00 horas para dejar el horario de noche. pico de demanda.

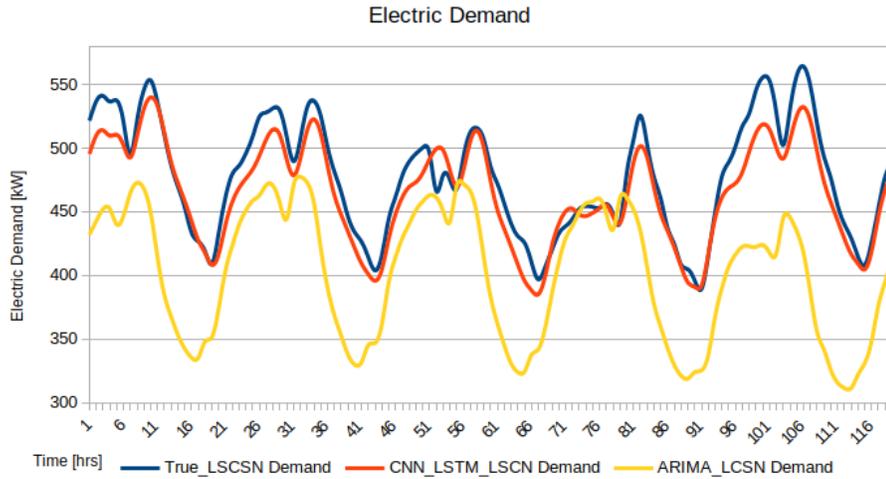


Figura 44: Predicción demanda eléctrica para 5 días en adelante.

Como se muestra en el Cuadro 5, los valores RMSE para el modelo CNN-LSTM son mucho más bajos que el benchmark ARIMA. Para evaluar el resultado del pronóstico a una escala más fina, en la Fig.45 se muestra una predicción de un día en adelante, está claro que el modelo ARIMA tiene un efecto predictivo mucho menor que el modelo propuesto CNN-LSTM para demanda eléctrica.

Cuadro 5: Comparación de las métricas estadísticas para las predicciones de ED.

Enfoque	MSE	RMSE	MAE
CNN LSTM 3	0.202267	0.449741	0.327231
ARIMA	0.937068	0.968022	0.956681

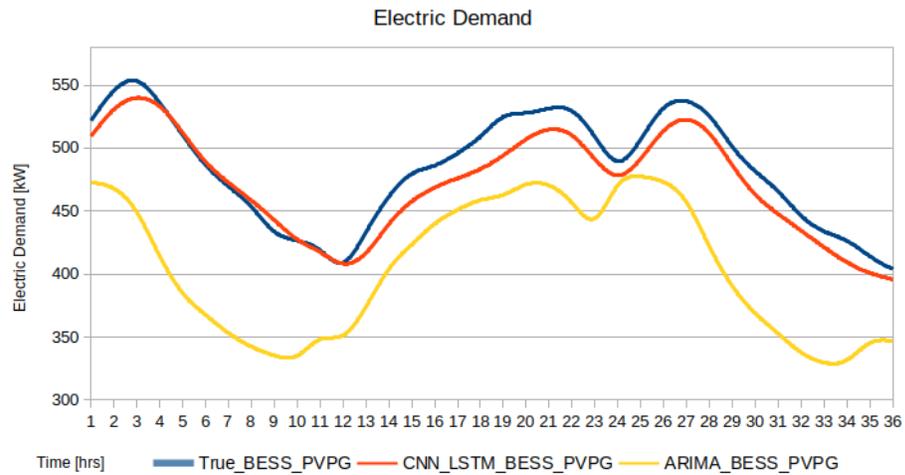


Figura 45: Predicción de demanda eléctrica para 36 horas en adelante.

Predicciones para generación fotovoltaica (PVPG).

El entrenamiento con la técnica de aprendizaje automático discutida anteriormente muestra claramente que no hay un comportamiento extraño como un ajuste insuficiente (underfitting) o excesivo (overfitting), incluso en días lluviosos. (Fig.46).

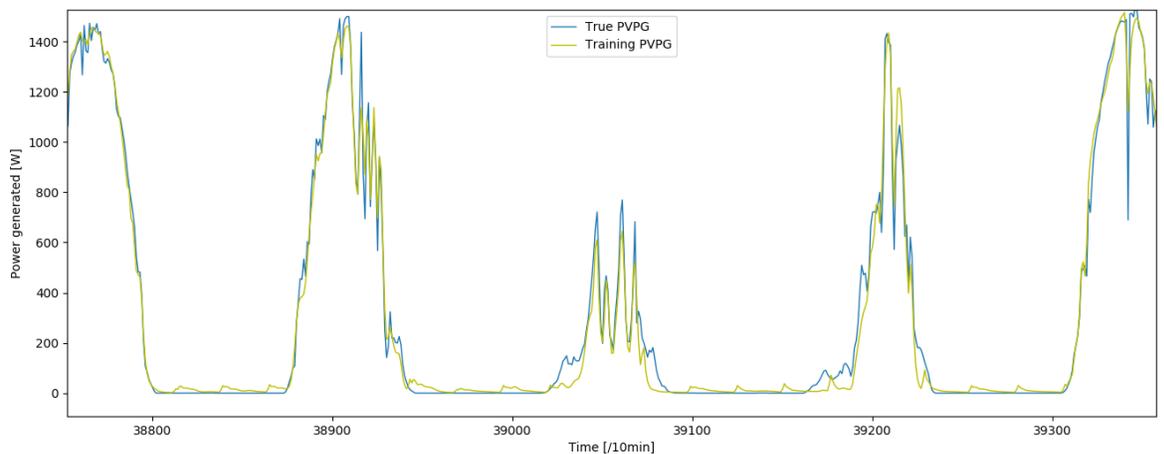


Figura 46: Entrenamiento del modelo CNN-LSTM para PVPG.

Estas predicciones de PVPG (Fig.47) se usarán en la siguiente sección para construir el estado de carga de un BESS ideal alimentado con PVPG.

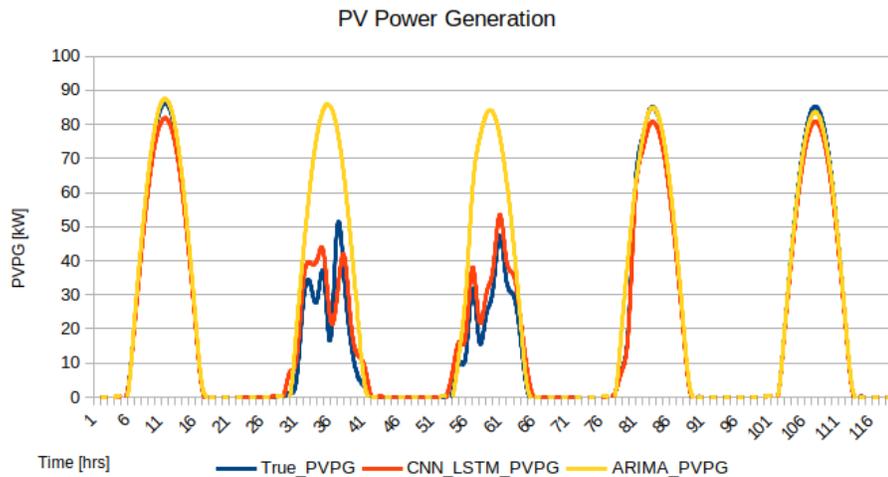


Figura 47: Predicción de PVPG para cinco días en adelante.

Como podemos ver en la Fig. 47, en este caso ambos modelos (amarillo y rojo) tienen un buen efecto predictivo para días con mucho recurso solar. Sin embargo para días con poco recurso, el efecto de predicción en el modelo ARIMA no es tan bueno como el de CNN-LSTM, este es el caso del segundo y tercer día. En general, podemos afirmar que el modelo híbrido propuesto tiene un mejor efecto predictivo que el enfoque ARIMA. Finalmente, podemos destacar que el RMSE del modelo híbrido CNN-LSTM es aproximadamente seis veces más pequeño que el benchmark ARIMA, ver Cuadro 6. Para evaluar el resultado del pronóstico a una escala más fina, en la Fig.48 se muestra una predicción de un día en adelante, está claro que el modelo ARIMA tiene un efecto predictivo mínimo en comparación con el modelo CNN-LSTM propuesto para PVPG.

Cuadro 6: Comparación de las métricas estadísticas de las predicciones de PVPG.

Enfoque	MSE	RMSE	MAE
CNN LSTM 3	0.057184	0.239131	0.054413
ARIMA	0.318736	0.564567	0.313131

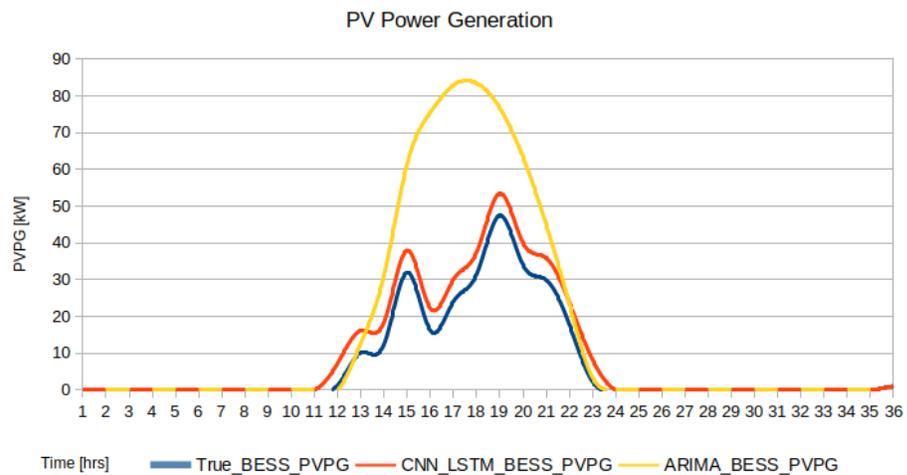


Figura 48: Predicciones de PVPG para 36 horas en adelante.

Predicciones para generación eólica.

En la Fig. 49, se muestra el entrenamiento del modelo WPG. Podemos observar que el modelo híbrido sigue efectivamente la compleja tendencia de la generación eólica no presenta un comportamiento extraño como un ajuste insuficiente o excesivo. Después de entrenar el modelo, hicimos una predicción de cinco días en adelante (Fig. 50) para construir un estado de carga del WPG-BESS con los itinerarios propuestos en la siguiente sección. Como podemos ver, el modelo CNN-LSTM (rojo) sigue la tendencia general de la generación eólica (azul). Por otro lado, para este caso el enfoque ARIMA (amarillo) tiene un efecto predictivo muy pobre.

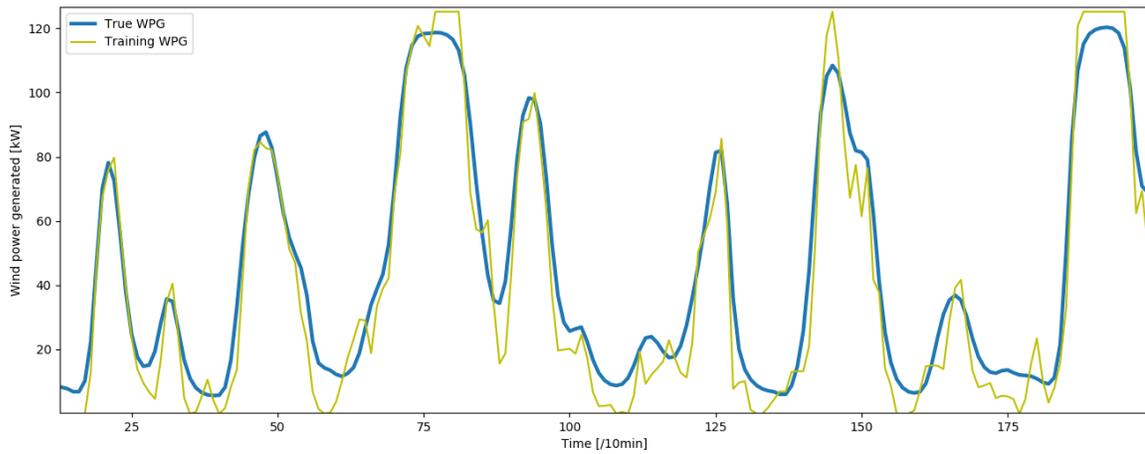


Figura 49: Entrenamiento del modelo CNN-LSTM para WPG.

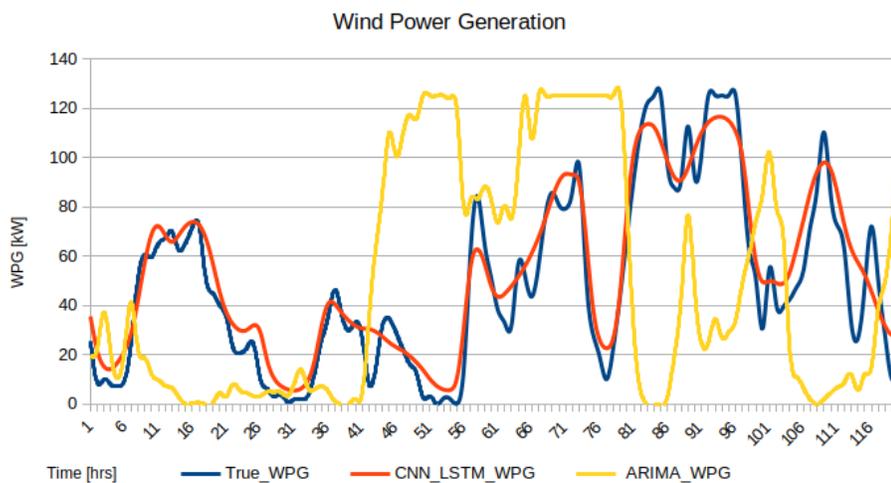


Figura 50: Predicción de WPG para cinco días en adelante.

Es de destacar el patrón totalmente desajustado de las predicciones hechas con el modelo ARIMA para el escenario eólico (Fig. 50); el buen desempeño del modelo de red neuronal híbrida para un fenómeno tan caótico como la generación eólica es sobresaliente, las métricas de los dos modelos comparados se muestran en el Cuadro 7. Para evaluar el resultado del pronóstico a una escala más fina, en la Fig.51 se muestra una predicción de un día en adelante, está claro que el modelo ARIMA tiene un efecto no predictivo total que el modelo CNN-LSTM propuesto para WPG.

Cuadro 7: Comparación de las métricas estadísticas de las predicciones de WPG.

Enfoque	MSE	RMSE	MAE
CNN LSTM 3	0.116356	0.341109	0.102273
ARIMA	4.278693	2.068500	4.018773

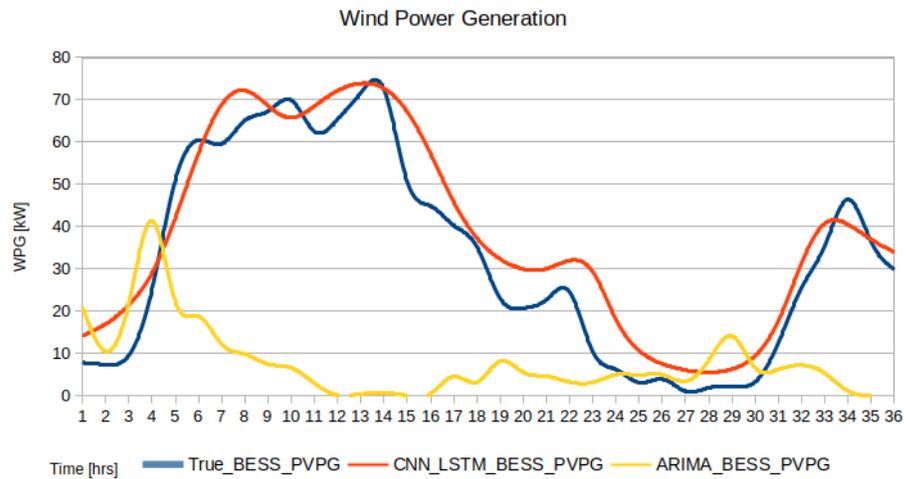


Figura 51: Predicción de WPG para 36 horas en adelante.

Itinerarios de carga y descarga en la zona de LCSN-BCS

Con las predicciones presentadas en el capítulo anterior (pags. 63-76) y el modelo de batería presentado en el caso de estudio de LCSN-BCS (págs. 53 - 55), construiremos dos itinerarios para dos modelos de BESS ideales. Uno alimentado con PVPG (Fig.52) para atender la demanda pico nocturna y un segundo BESS ideal alimentado con WPG (Fig.53) para atender la demanda pico diurna. También construimos los itinerarios óptimos reales basados en observaciones reales para comparar los dos modelos (CNN-LSTM y ARIMA).

Para ser más claros, las predicciones de PVPG y WPG nos ayudaron a determinar cuándo cargar cada BESS y cuánta energía estará disponible para cargar, ya sea de fuente solar o eólica, finalmente el modelo de predicción ED para LCSN- Área BCS, determinó cuándo descargar estos sistemas para apalancar los picos de la demanda local.

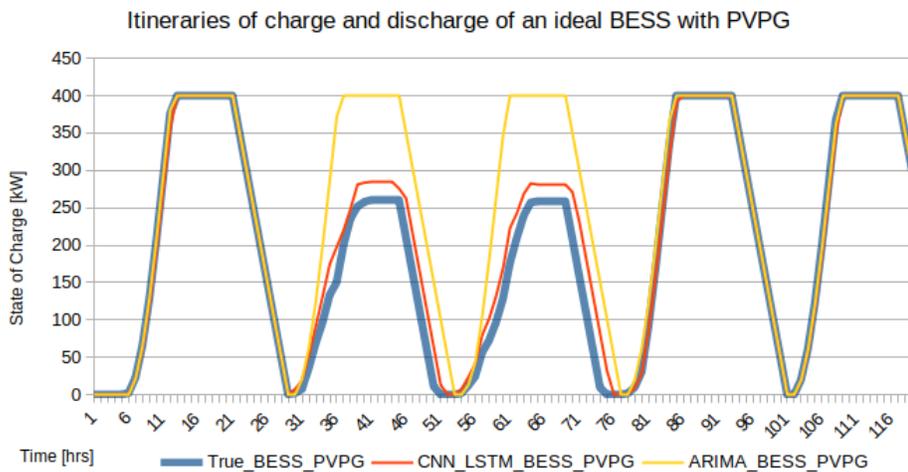


Figura 52: Itinerarios de carga y descarga para el sistema PVPG-BESS.

Como podemos ver en la Fig. 52, ambos enfoques funcionan cuando el recurso solar está disponible, sin embargo, para el segundo y tercer día, cuando el recurso solar es escaso, los itinerarios CNN-LSTM basados en redes neuronales CNN-LSTM, funciona mejor, ya que podemos ver el error a lo largo del tiempo en la Fig.54. Ver la comparación de métricas en el Cuadro 8.

Cuadro 8: Comparación de las métricas estadísticas para el PVPG-BESS itineraries

Enfoque	MSE	RMSE	MAE
CNN LSTM 3	0.174132	0.417291	0.112337
ARIMA	0.748722	0.865287	0.706894

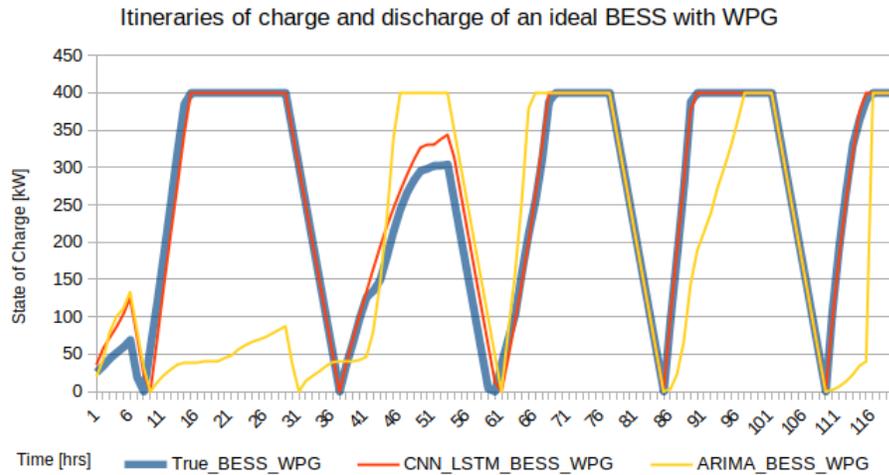


Figura 53: Itinerarios de carga y descarga para el sistema WPG-BESS.

Para el segundo BESS (Fig.53), el enfoque ARIMA no está bien ajustado en ninguno de los cinco días; por otro lado, para los itinerarios de carga y descarga basados en el modelo CNN-LSTM, los encontramos muy precisos cuando el recurso eólico es abundante, y registramos algún error cuando el recurso eólico es escaso (Fig.55).

Cuadro 9: Comparación de las métricas estadísticas para el WPG-BESS itineraries

Enfoque	MSE	RMSE	MAE
CNN LSTM 3	0.218728	0.467684	0.195587
ARIMA	4.818722	2.133484	4.317960

Como podemos observar en el Cuadro 8, el RMSE del modelo propuesto es aproximadamente cuatro veces menor que el enfoque ARIMA para el PVPG-BESS. Y para los BESS alimentados con WPG, un RMSE siete veces menor que ARIMA (ver Cuadro 9). Encontramos que el error en el modelo propuesto, ocurre principalmente en las horas con poco recurso solar y eólico (Fig. 54 y Fig.55).

Gracias a los modelos CNN-LSTM, pudimos encontrar un perfil preciso (en comparación con el otro basado en el benchmark ARIMA), para cargar los dispositivos de almacenamiento para que se carguen a la velocidad correcta en periodos diurnos (PVPG-BESS), o en periodos nocturnos en el escenario WPG-BESS. Y descargas a la velocidad correcta durante cierto período de la mañana o de la tarde con el fin de aplanar los picos de demanda. Con este nuevo método pretendemos dar confiabilidad a la generación solar o eólica, que es uno de los temas más criticados de estas fuentes variantes [81].

Finalmente, experimentamos con una escala más fina y con diferentes horizontes temporales de predicción para los itinerarios, ver Cuadro 10. Estos resultados muestran que un RMSE para el modelo propuesto es más bajo que un modelo LSTM de una sola capa; pero debe ser importante, inferior al benchmark competitivo ARIMA en todos los casos (ver Cuadro 10 y Fig. 56).

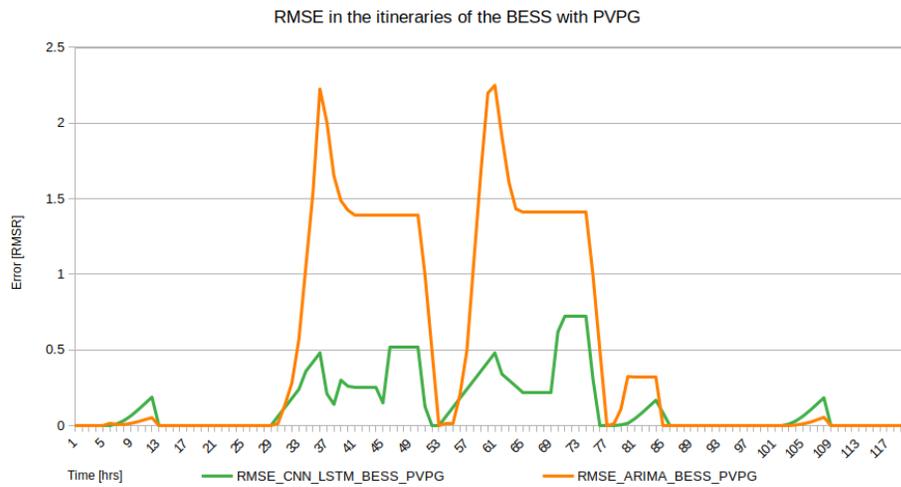


Figura 54: El error (RMSE) a lo largo de 5 días para los itinerarios del PVPG-BESS.

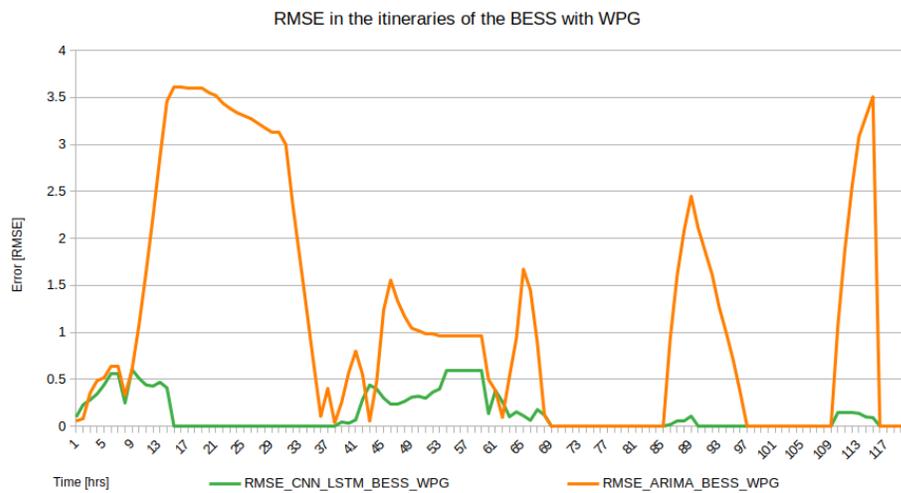


Figura 55: El error (RMSE) a lo largo de 5 días para los itinerarios del WPG-BESS.

Cuadro 10: Comparación del desempeño de los itinerarios hechos con el enfoque propuesto y con ARIMA.

Enfoque	MSE	RMSE	MAE
CNN-LSTM-3	0.005766	0.075935	0.005248
LSTM	0.082337	0.286944	0.081326
ARIMA	0.109811	0.331377	0.131796
<i>Horizonte de predicción = 10 minutes</i>			
Enfoque	MSE	RMSE	MAE
CNN-LSTM-3	0.0086493	0.0930016	0.008132
LSTM	0.1235061	0.3514343	0.1362685
ARIMA	0.2647165	0.5145060	0.2317960
<i>Horizonte de predicción = 30 minutes</i>			
Enfoque	MSE	RMSE	MAE
CNN-LSTM-3	0.02335311	0.1528172	0.0210977
LSTM	0.18525915	0.43041741	0.1716833
ARIMA	0.4447345	0.66688421	0.4210274
<i>Horizonte de predicción = 60 minutes</i>			
Enfoque	MSE	RMSE	MAE
CNN-LSTM-3	0.063053397	0.2511043	1.313268
LSTM	0.277888725	0.5271515	0.310661
ARIMA	0.65128761	0.8070239	0.619982
<i>Horizonte de predicción = 90 minutes</i>			
Enfoque	MSE	RMSE	MAE
CNN-LSTM-3	0.0977228	0.3126065	0.1068111
LSTM	0.4168330875	0.6456261	0.443303
ARIMA	0.892416371	0.9446779	0.8671888
<i>Horizonte de predicción = 120 minutes</i>			
Enfoque	MSE	RMSE	MAE
CNN-LSTM-3	0.1597728	0.3997159	0.1514280
LSTM	0.6252496	0.7907272	0.6021421
ARIMA	1.4179726	1.1907865	1.4772368
<i>Horizonte de predicción = 150 minutes</i>			
Enfoque	MSE	RMSE	MAE
CNN-LSTM-3	0.2260662	0.4754642	0.2620961
LSTM	0.9378744	0.9684391	0.9004295
ARIMA	1.9361528	1.3914571	1.921515
<i>Horizonte de predicción = 180 minutes</i>			

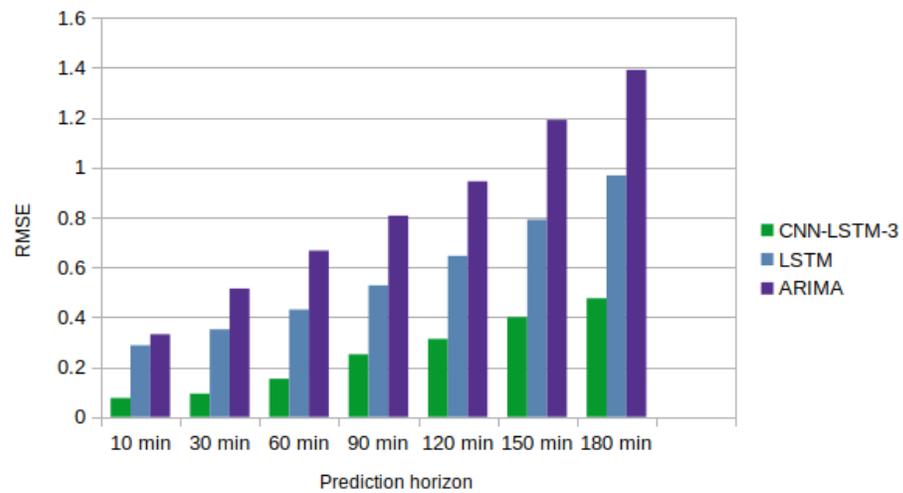


Figura 56: Comparación del desempeño de los itinerarios hechos con el enfoque propuesto, hechos con ARIMA y hechos con un modelo LSTM uni-capas, con diferentes horizontes de predicción.

Rasurado de picos con itinerarios de un BESS ideal basado en predicciones de un modelo CNN-LSTM en la zona de LCSN-BCS

Como explicamos en la sección 1.2, la reducción de picos en un escenario con BESS impulsado por REG puede reducir el uso de plantas de energía convencionales, que a menudo usan combustibles fósiles, como en el caso de la red eléctrica de BCS. Además, el uso de estas plantas de energía eléctrica es costoso debido al aislamiento de la región [7, 29, 30].

El uso de itinerarios de carga y descarga con un enfoque basado en datos muestra un mejor rendimiento para predecir cuándo cargar y cuándo descargar la energía de fuentes intermitentes, en comparación con otros puntos de referencia conocidos, consulte las Figs. 52 y 53.

Finalmente, en esta última sección presentamos el efecto de los dos BESS ideales en los dos picos del área de estudio, (Figs 57 y 58). Como era de esperar, los días con menos recursos tienen menos efecto que los días en que el recurso es abundante. Tenga en cuenta que el primer día los BESS no surtieron efecto porque asumimos que arrancamos los sistemas de baterías completamente descargados.

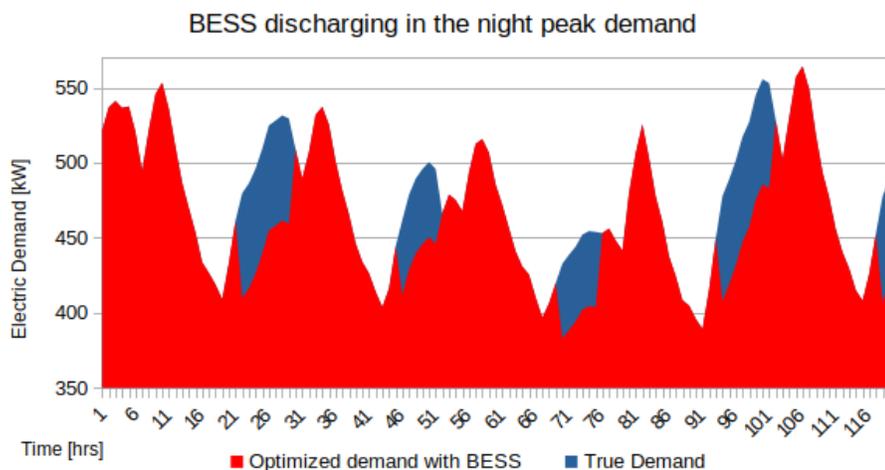


Figura 57: Rasurado de picos en la noche con itinerarios de PVPG-BESS.

También hay que resaltar que en algunos casos se cargó completamente el BESS y hubo excedentes de energía. En el caso del WPG-BESS por ejemplo, en los días 4 y 5 el recurso eólico fue tan abundante en la ventana de tiempo del segundo pico, que la reducción del mismo fue sobresaliente, ver Fig.58.

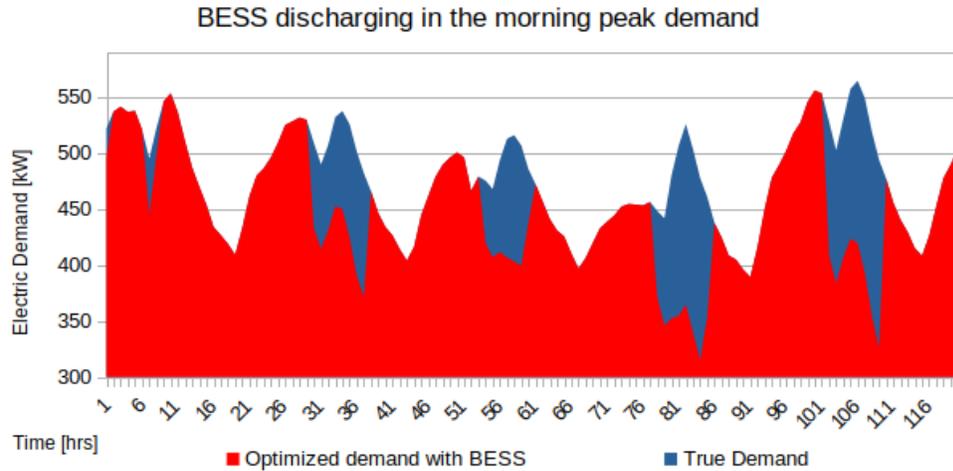


Figura 58: Rasurado de picos en la mañana con itinerarios de WPG-BESS.

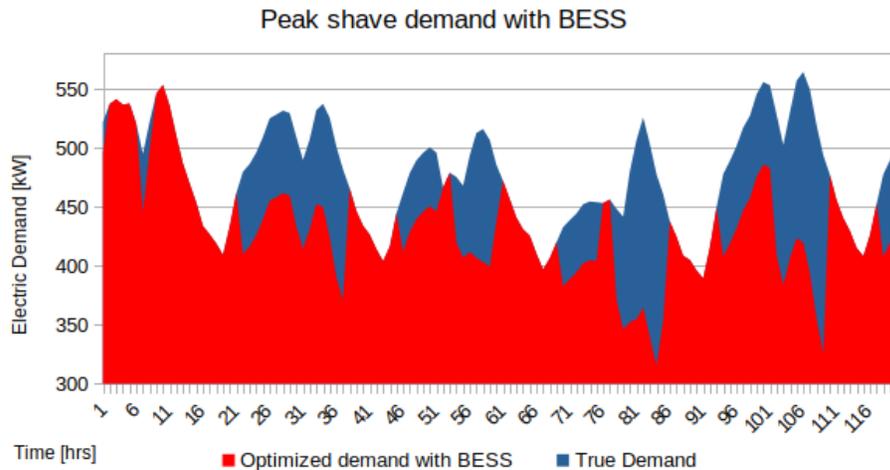


Figura 59: Rasurado de picos en periodos de mañana y noche con itinerarios de PVPG-BESS y WPG-BESS.

La Fig. 59 muestra el efecto de los dos BESS basados en itinerarios con un enfoque de predicción de redes neuronales. Para este trabajo suponemos que los dos BESS ideales

están totalmente descargados por lo que en el primer día hay un efecto mínimo en la demanda. Sin embargo, para los próximos 4 días podemos observar que los valores de demanda optimizados no superan los $490 - 450[kW]$. Aunque cabe destacar que lo que se busca es que la demanda sea una curva lo más plana posible, este efecto podría lograrse si se incluye un proceso de optimización en base a una función económica, este caso se expondrá en el último caso de estudio también en la zona de BCS.

Conclusiones

El caso de estudio en Temixco, Morelos, nos permitió hacer uso de herramientas computacionales de frontera, como son las llamadas redes neuronales, esto nos permitió experimentar con ellas y aprender a generar modelos que fueran fiables por su precisión [72].

En el segundo caso de estudio, introducimos un elemento esencial, un sistema de almacenamiento con un generador fotovoltaico en una locación del Reino Unido, esta experiencia fue fundamental para darle una aplicación a dichas predicciones hechas con redes neuronales.

En el tercer caso de estudio se añaden dos elementos más: un generador eólico con su sistema de almacenamiento, es en este caso de estudio que se profundiza más la aplicación de las predicciones de series temporales de energía (demanda y generación), para aumentar la penetrabilidad de la generación renovable con itinerarios inteligentes de carga y descarga de dos BESS ideales.

Presentamos el caso de BCS en la localidad de Los Cabos San Lucas debido a que el recurso solar y eólico en la región es abundante [9]. Utilizamos los datos meteorológicos y de demanda eléctrica disponibles para la región de LCSN-BCS, para entrenar un modelo híbrido de red neuronal CNN-LSTM, las predicciones de PVPG y WPG nos ayudaron a saber cuándo cargar cada BESS. Y el modelo ED CNN-LSTM nos ayudó a saber cuándo ocurrirá el pico y por lo tanto descargar la energía de REG. En otras palabras, el propósito del modelo BESS es maximizar la reducción máxima de la mañana y la tarde para la demanda con dos alimentadores de distribución para cada día, durante un período de cinco días, mientras se utiliza la mayor cantidad posible de

PVPG o WPG solar para lograrlo.

Esto se logra encontrando un perfil de carga apropiado para el dispositivo de almacenamiento, de modo que se cargue a la tasa correcta durante los períodos diurnos (o nocturnos) cuando hay mucha generación solar o eólica, y se descargue a la tasa correcta durante cierto período en el mañana o por la tarde.

Los resultados muestran una mayor precisión para los itinerarios basados en redes neuronales híbridas, en comparación con los itinerarios basados en una benchmark bien conocida (ARIMA) [75]. Para la potencia BESS por PVPG, encontramos que el error (RMSE) es aproximadamente 4 veces menor que el enfoque ARIMA (Cuadro 8). Y aproximadamente 6 veces menos error para el BESS impulsado por WPG (ver Cuadro 9).

Para los casos solar y eólico (Figs. 52 y 53), encontramos que los días en que el recurso es escaso y con un alto comportamiento intermitente, los itinerarios con el enfoque neuronal híbrido funcionaron mejor que los basados en ARIMA. itinerarios (Figs. 54 y 55). El buen rendimiento de predictibilidad de los itinerarios basados en redes neuronales híbridas podrá aumentar la fiabilidad energética y, por tanto, la penetración de fuentes renovables intermitentes.

También experimentamos con una escala más fina y con diferentes horizontes temporales de predicción para los itinerarios (10 min, 30 min, 60 min, 90 min, 120 min, 150 min y 180 min). Estos resultados muestran que el RMSE del modelo propuesto es más bajo que el punto de referencia competitivo de ARIMA y un newtok neuronal LSTM de una sola capa en todos los casos (consulte Cuadro 10 y la Fig. 56).

Debemos señalar que el modelo presentado para el BESS es una idealización, los estudios adicionales deben incorporar un modelo más realista que considere los materiales de la batería, el estado de la vida útil de la batería, etc.

Además, presentamos el efecto de reducción de picos de los itinerarios propuestos basados en redes neuronales híbridas en la demanda eléctrica local Fig.59 de LCSN-BCS. Creemos que la implementación de esta estrategia para prosumidores (usuarios que consumen y producen electricidad) en escenarios de microrredes (MG) tendrá un efec-

to positivo para la red de distribución eléctrica general en una ubicación [15], pero se necesitan más estudios hacerse.

El último caso de estudio, se analiza la zona de Mulegé en BCS, muy parecido al caso de LCSN; en Mulegé se trató de introducir al análisis una parte de optimización, teniendo como objetivo optimizar una función económica. Debido a los tiempos del doctorado, no se lograron obtener resultados en este último caso, sin embargo se incluye a manera de pantlemiento de un problema para la tesis de licenciatura del alumno Samuel Salinas Trujillo de la LIER.

También se incluye una propuesta de un medidor de hardware libre para sensar datos de variables eléctricas y con esto generar datasets con los cuales se puedan estudiar el impacto de diferente técnicas aplicadas a las energías renovables en cualquier localidad.

No hay que olvidar que la innovación de este trabajo es la fusión de técnicas de inteligencia artificial con las energías renovables, logrando generar itinerarios precisos para un BESS. Para llegar a ese punto, cabe recalcar que podemos ir viendo una evolución de los elementos según cada caso de estudio.

En el caso Temixco se aprendió a programar y entrenar con datos reales una red neuronal [72] y se tiene como principal actor un generador fotovoltaico, en el caso de Reino Unido, se tiene un generador fotovoltaico y un sistema de almacenamiento; finalmente para los casos de estudio de BCS, el modelo correlaciona los datos de un generador fotovoltaico y un generador eólico y se hace un escenario donde se administra la energía de un sistema de almacenamiento alimentado con energía del generador fotovoltaica y un sistema de almacenamiento alimentado con el generador eólico [75]. En esta perspectiva podemos decir que se estudiaron las dinámicas de transacciones energéticas dentro de un sólo prosumidor. Es en este sentido hacen falta más estudios donde el BESS pueda vender esa energía en el mercado energético. El último caso trata de analizar este escenario donde se añade al análisis, la parte de la optimización de la variable económica.

También es importante recalcar que se cumplieron los objetivos planteados para este trabajo,

Capítulo IV: Mulegé - BCS.

Este caso de estudio, también en BCS, se escogió para tratar de incorporar al problema de los itinerarios, un problema de optimización teniendo como función objetivo una variable económica. Este caso de estudio se deja como trabajo futuro para la generación de conocimiento.



Figura 60: Mapa de la red de transmisión de Mulegé.

Además hay que resaltar que la zona de Mulegé, es una zona privilegiada en cuanto

a recurso solar, eólico y geotérmico se refiere. Si observamos el mapa actual de la red de transmisión en la zona de Mulegé, podemos constatar que actualmente existen una planta geotérmica, turbogás, solar y eólica.

Cuadro 11: Centrales Generadoras en Mulegé (BCS), zona Snta Rosalía.

Central	Tecnología de Generación	Capacidad [MW]
C.TJ. Santa Rosalía	Turbojet	12.5
C.G.T. Tres Vírgenes	Geotérmica	10
C.D. Santa Rosalía	Diésel Eléctrica	7.15
C.D. Santa Rosalía Respaldo	Diésel Eléctrica	11.3
C.S.FV. Santa Rosalía	Solar Fotovoltaica	1
TOTAL	Todas	58.9

Fuente: SENER, CFE y CENACE, 2021 [12], [7], [29]

Sistema Mulegé - Baja California Sur

El sistema eléctrico de Baja California Sur se divide en tres regiones: Constitución, La Paz y Los Cabos. En el mapa de la Fig. 60 se muestra un esquema general de este sistema de transmisión, incluyendo las tres zonas del sistema y la ubicación actual de los principales centros de carga y las centrales generadoras. Como se puede apreciar en la Fig. 60, actualmente existen 28 centros de consumo, 2 centrales de combustión interna, 3 de turbogás, 1 termoeléctrica, 1 de ciclo combinado, 1 parque eólico y 3 solares fotovoltaicos, sumando una capacidad instalada total de 883.805 MW [29].

En el Cuadro 11 se presenta la información de cada central de generación, incluyendo nombre, tecnología de generación y capacidad instalada.

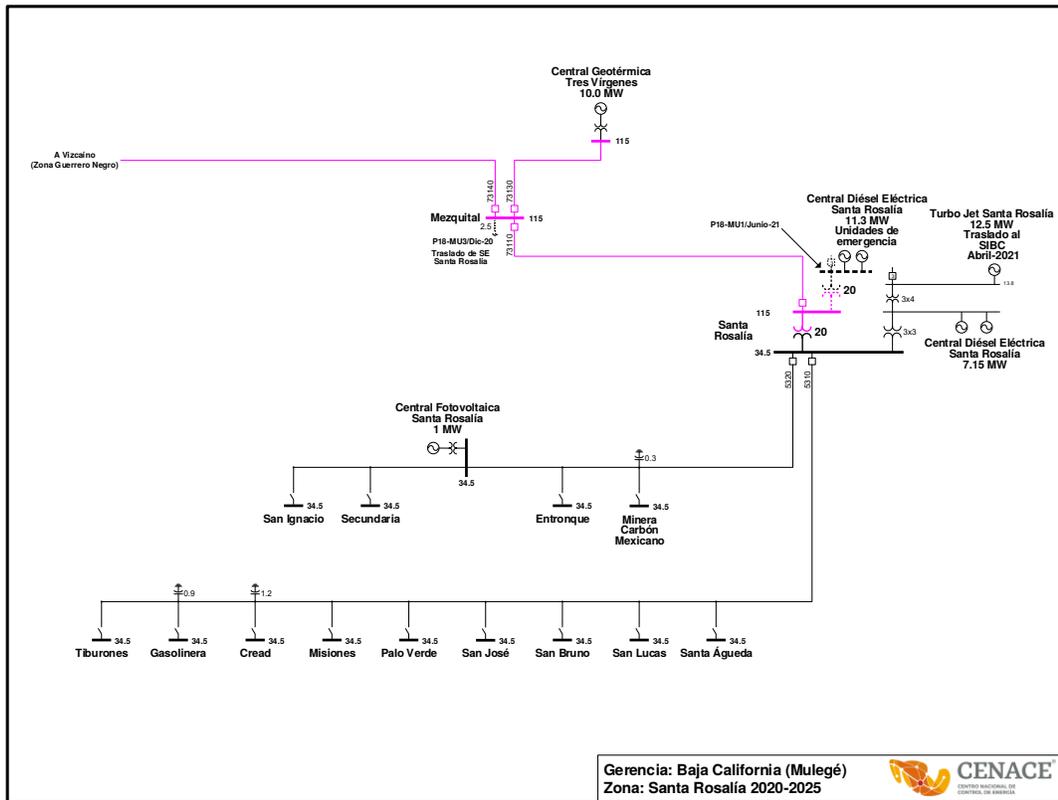


Figura 61: Diagrama Unifilar de Mulegé [17].

Ventana de descarga en base a tarifas de CFE.

En el caso anterior se usaron predicciones de la demanda local para buscar los picos y por lo tanto comenzar el proceso de descarga, en este caso de estudio vamos a usar como ventanas de descarga la propia información de CFE.

Con base a las tarifas de CFE de gran demanda en media tensión horaria [7], se tiene que para la región de BCS. Los periodos de punta, intermedio y base, se definen en cada una de las regiones tarifarias para distintas temporadas del año, como se describe en el apartado 3.3.4 del Anexo Único del Acuerdo A/064/2018. Para el caso de estudio el periodo de punta para BCS es de Lunes a Viernes de 12:00 - 22:00 y Sábados de 19:00 - 22:00.

Dado que se está hablando de usuarios de gran demanda en media tensión, se propone utilizar los datos de propios de SENER para la industria pesquera y proponer un

prosumidor que tenga este perfil de consumo (ver Fig. 62).

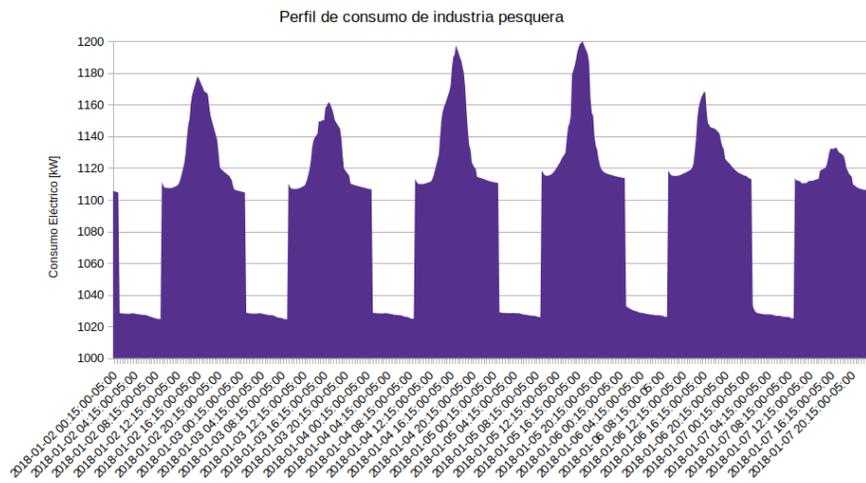


Figura 62: Demanda de una procesadora pesquera - BCS [Fuente: SENER 2021]

Variables climáticas en la región de Mulegé-BCS

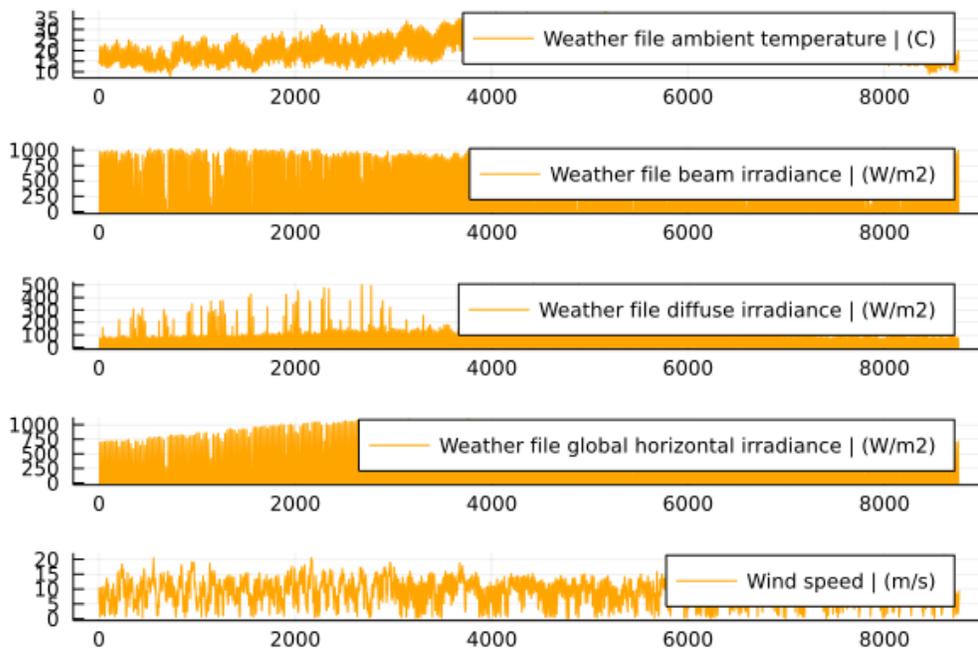


Figura 63: Variables climáticas en Mulegé-BCS.

De igual manera que en los casos anteriores, se propone construir un dataset en base a los datos de variables climáticas disponibles en la región de BCS por el NREL. Entre dichas variables podemos destacar temperatura, velocidad de viento, irradiancia difusa, irradiancia global, etc. Ver Fig.63.

Propuesta para el algoritmo de optimización en base a tarifas de CFE

El objetivo principal en este caso es satisfacer la demanda, especialmente cuando el horario de costo es punta (mayor costo de la energía), de esta manera se apunta a optimizar una variable económica. Para ello, tomando en cuenta que tenemos un sistema de baterías, se puede crear un algoritmo que nos permita entender con mejor detalle la solución del problema e identificar los itinerarios correctos. De forma simple, podemos decir que la batería debe descargarse cuando el horario sea punta, siempre y cuando no exista generación de las fuentes renovables. En caso de que exista una generación de dichas fuentes, se puede satisfacer la demanda sin necesidad de recurrir a la batería, incluso si es el horario punta. Pero en caso de que el horario no sea punta y exista generación, puede redirigirse esta energía hacia la batería para cargarla, de este modo, aunque parte de la energía generada no sea destinada a satisfacer la demanda, se estará guardando para usarla en los momentos en los que el precio de la energía sea más elevado y es en este momento cuando dicha energía guardada podrá satisfacer la demanda y así ahorrar una mayor cantidad de dinero.

Con ayuda del diagrama de flujo (Fig. 64) queda mejor representado las diferentes posibilidades y con su ayuda podemos comenzar a tener una idea del planteamiento de este problema. El único momento donde la batería podrá descargarse es mientras no exista una fuente renovable que esté generando y sea horario punta. Además, en los momentos donde la energía generada sea destinada a cargar la batería, una vez que se encuentre completamente llena, se vuelve a redirigir esta energía para satisfacer la demanda.

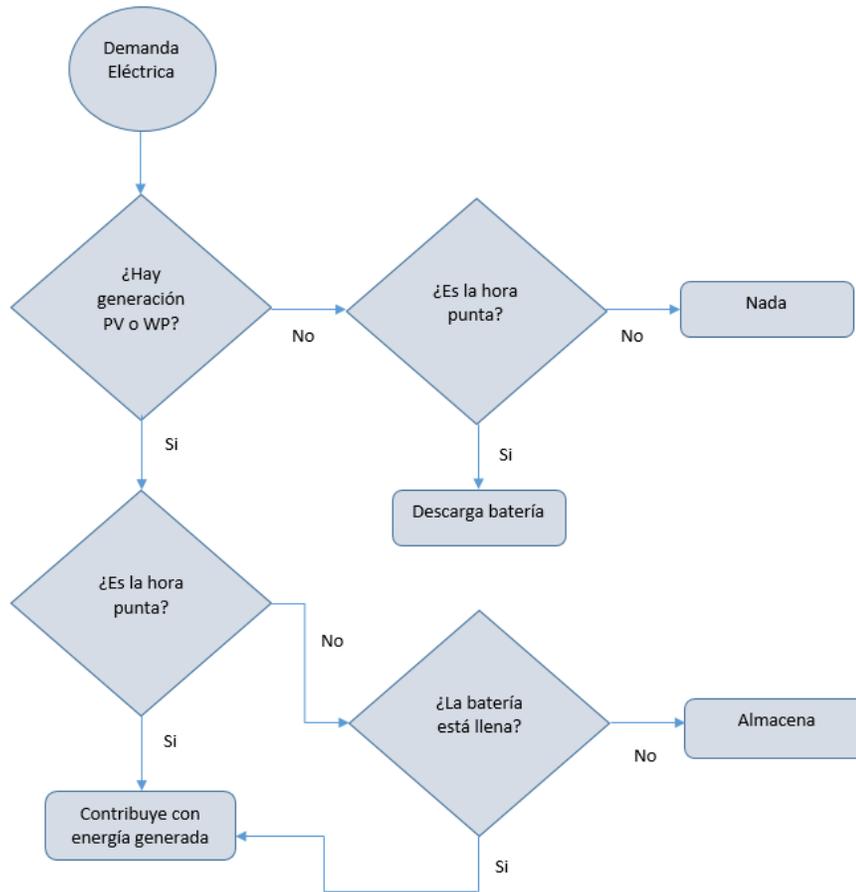


Figura 64: Diagrama de flujo para la optimización de itinerarios.

El siguiente paso es formular el problema de optimización para los itinerarios de una forma matemática, lo que además de ayudarnos a solucionar el problema, también nos facilitará implementar el código que se programará en python mas adelante. Tomando en cuenta que estaremos trabajando con series de datos podemos nombrar las siguientes variables como:

$$D_{elect} = \{D_0, D_1, \dots, D_k\}. \quad (21)$$

Donde D_{elect} es la potencia eléctrica consumida en la zona de Mulegé, en [kW], la variable k se refiere al número total de muestras, en este caso k tiene una resolución horaria (24 horas por cada día).

$$G_{ren} = \{G_0, G_1, \dots, G_k\} = G_{pv} + G_{eolica}. \quad (22)$$

G_{ren} se refiere a la generación renovable, en nuestro caso, esta tiene un componente de PVPG (G_{pv}), y otro componente de generación eólica (G_{eolica}).

$$h_k = \{h_0, h_1, \dots, h_k\}, \quad (23)$$

h_k es cada una de las horas del día que se usara para definir los intervalos de carga y descarga de la batería.

$$h_k = h_{carga(k)} \rightarrow Carga, \quad (24)$$

$$C_k = G_{ren}(k),$$

$C_{d,k}$, como ya habíamos mencionado, es la carga total de la batería en (kW) en el día d y hora k . La carga del BESS comenzará si se encuentra dentro del horario de carga (se establece de acuerdo al horario punta) (eq. 24), es decir, el BESS se cargará en el horario en el cual no sea punta. Para la descarga haremos lo mismo, fijaremos un horario de descarga, si nos encontramos dentro de ese horario y no hay generación renovable, entonces descargamos el BESS.

$$h_k = h_{descarga(k)} \rightarrow Descarga. \quad (25)$$

En este punto es importante recordar que este sistema se estará empleando dentro de una micro-red. Esto nos permite sacar provecho de la energía que podría no estarse ocupando ni para cargar la batería ni para satisfacer la demanda. Y es que es importante contemplar este hecho dado que el número de diferentes resultados puede dar lugar a este último escenario donde hay generación renovable, pero no hay demanda y además la batería se mantiene cargada porque no ha llegado el horario de descarga. En este caso tenemos que contemplar la energía residual (entiéndase por energía residual la energía que está siendo generada por las fuentes renovables, pero que no se está utilizando de ninguna manera).

De acuerdo a lo anterior, la energía residual E_{res} la podemos definir como la diferencia entre la demanda eléctrica y la generación renovable (G_{ren}).

$$E_{res(k)} = D_{elect(k)} - G_{ren(k)}. \quad (26)$$

Si se enfoca en sólo cargar el BESS, la energía residual sería:

$$E_{res(k)} = G_{ren(k)} - C_k. \quad (27)$$

Para este caso, si:

$$E_{res(k)} \leq 0 \rightarrow C_k = G_{ren(k)}.$$

Y en el caso de que se cargue la batería y además parte de la generación esté contribuyendo en la red eléctrica una vez que la batería se haya llenado por completo tendríamos lo siguiente:

$$E_{res(k)} = D_{elec(k)} - (C_k + G_{ren(k)}). \quad (28)$$

Con el cálculo de la energía residual puede plantearse entonces su uso para otros fines, además del autoconsumo. Al estar este sistema dentro de un nodo en un micro-red podemos redirigir el flujo de la energía hacia otro nodo donde la demanda de energía sea elevada y pueda ser utilizada, de esta manera el consumidor puede convertirse ahora en un prosumidor al vender este exceso de energía a otro usuario de la micro-red. Esto nos plantea la posibilidad de sobredimensionar el sistema intencionalmente con el objetivo de tener siempre un exceso de energía que podrá almacenarse en el sistema de baterías para posteriormente, además de usarse para satisfacer la demanda de la propia industria en horas pico, venderse para poder aportar energía a la micro-red en otras zonas. De hecho, este sería uno de los principales objetivos de una micro-red, que los usuarios en su mayoría tuvieran la facultad de prosumidor.

Ahora que tenemos el planteamiento del problema con las variables que necesitamos podemos programar el código en python que con ayuda de datos reales y las simulaciones elaboradas en SAM, nos permitirán obtener resultados cuantificables y una mejor visualización del flujo de la energía dentro del sistema. Con ello podremos finalmente dar solución a los problemas de los itinerarios de carga y descarga del BESS de una forma automatizada.

Funcionamiento del algoritmo propuesto.

Primeramente se empezó por obtener los datos de la demanda y la generación. Se fijaron las horas de descarga de el BESS con base en las ventas de descarga definidas en capítulos anteriores, la cual, se fijó de acuerdo a los horarios punta (recordemos que horario punta se refiere a los horarios de mayor precio de la energía) establecidos por CFE en la zona de Mulege. De igual manera se definen las pérdidas asociadas a la transmisión de la energía hacia la batería y de la batería hacia la red eléctrica.

Dentro de la función principal del programa se encuentra el algoritmo de la Fig. 64. El programa está diseñado para iterar cada una de las horas que transcurren a lo largo del año. Los datos de la demanda y las simulaciones de la generación renovable, mantienen intervalos de tiempo de 1 hora entre cada registro, por ello es necesario que todo esté referenciado hacia una hora, denominada *K*.

Posterior al inicio de este ciclo, comienza la toma de decisiones que acontece de forma breve de la siguiente manera: Si existe generación renovable se revisa si hay demanda, si no, se procede a descargar la batería siempre y cuando esta se encuentre cargada y además estemos dentro del horario punta. Si hay demanda se revisa si estamos dentro del horario punta, si no, la energía que se esté generando se redirige hacia la batería para cargarla siempre y cuando no esté cargada por completo, de lo contrario, la generación se mantiene contribuyendo para disminuir la demanda eléctrica. Sí estamos dentro del horario punta, entonces la energía generada contribuye a disminuir la demanda, si no, se carga la batería. Si la batería no está cargada por completo se procede a cargar, si no, la única opción es contribuir nuevamente en la disminución de la demanda.

Capítulo V: Trabajo futuro.

Nuevos avances en técnicas de aprendizaje automático, como mecanismos de atención[71] o redes neuronales de ecuaciones diferenciales ordinarias (ODE) [82], etc. Estos modelos novedosos tienen como objetivo aumentar la precisión y la eficiencia de la memoria en la previsión de series temporales. Se deberían estudiar otras técnicas como el aprendizaje por refuerzo [83] para incorporarlas en los modelos de predicción.

Además, los nuevos enfoques como la lógica difusa[84] o la regularización de red elástica [78] han logrado resultados sobresalientes en la gestión energética y la toma de decisiones en MG. El rendimiento de estos modelos, con los modelos híbridos de redes neuronales profundas, debe compararse y estudiarse en detalle.

Se debe abordar el estudio de modelos continuos, livianos y eficientes en memoria, como [82] neuronal ODE. Además, la incorporación de GPU de propósito general de bajo costo (como la serie Jetson NVIDIA) en MG con REG aumentará la confiabilidad, al brindarle al prosumidor una herramienta poderosa para aprender diferentes características espaciales y temporales de diferentes datos de series de tiempo como demanda y generación local.

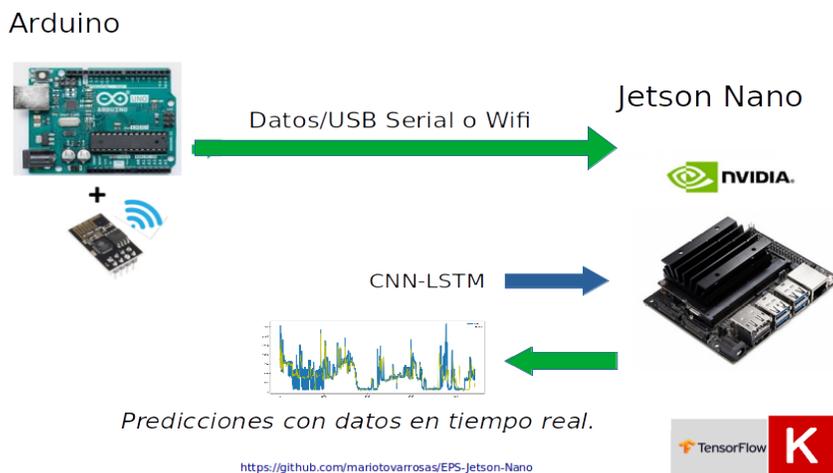


Figura 65: Sistema de pronósticos con un GPU de propósito general.

Ya que las redes inteligentes apuntan a la digitalización. A continuación se da una propuesta para construir un medidor de potencia activa con Hardware Libre que pretende dar una respuesta a la falta de datos a nivel prosumidor. Al igual que una propuesta para un circuito de conmutación de cargas de forma remota, teniendo como perspectiva utilizarlo para conmutar cargas como una lavadora acorde a los precios de la energía.

Medidor de potencia eléctrica conectado a Internet

La digitalización de la red eléctrica conlleva la instrumentación dispositivos electrónicos capaces de medir variables eléctricas y transmitir las a un servidor remoto. En esta sección se propone un medidor de potencia eléctrica buscando un bajo costo para fomentar su reproducibilidad.

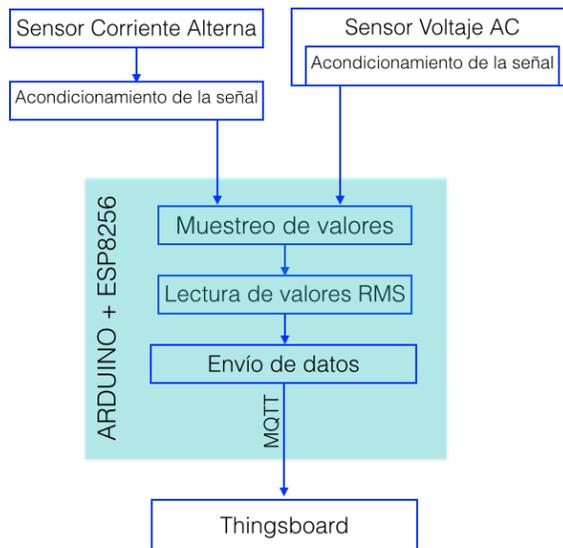


Figura 66: Diagrama de bloques para un medidor de potencia.

En cuanto al dispositivo propuesto, podemos decir que se compone de dos partes principales, una parte para medir la corriente alterna y un sensor de voltaje para medir la diferencia de potencial en AC. En la Fig. 66 podemos ver el diagrama de bloques de este dispositivo. Por un lado, la señal del sensor de corriente pasa por una etapa de acondicionamiento, ya que los voltajes negativos pueden dañar la placa Arduino. Para el sensor de voltaje, la etapa de acondicionamiento está inmersa en el propio sensor (ZMPT101B - Fig. 68), por medio de un offset.

Después, la placa Arduino se encarga de tomar muestras, por medio de un convertidor analógico/digital. El Arduino dispone de 6 convertidores analógico a digital (ADC-pines A0 a A5), $V_{in_{max}} = 5[V]$ $I_{max} = 40[mA]$). Una de las características claves del convertidor, es su número de bits, que define la finura con los que podemos cuantificar esa conversión a digital, cuanto mayor sea esta resolución mejor es la capacidad de aproximación al valor real.

En el caso de Arduino, son 10 los bits que maneja en la puertas analógicas, lo que significa que su resolución es $2^{10} = 1024$ posibles valores. En un convertidor como los de Arduino con 10 bits de resolución, cada escalón de medida es de $5V/1024 = 0,0048828125V$, aprox. 5mV, lo que significa que el Arduino no puede discriminar entre valores de tensión menores que esto. Si cambiamos el valor de referencia por uno de

1.1V, los escalones serian de: $1,1V/1024 = 0,00107421875$ o sea 1 mV.

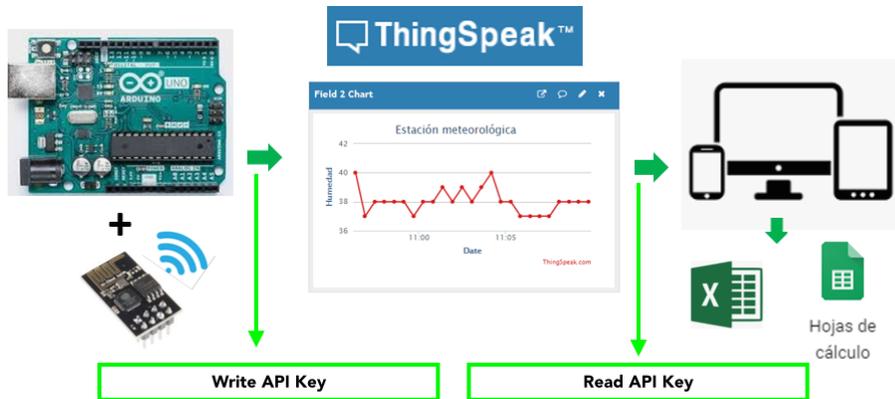


Figura 67: Modelo para IoT del dispositivo con base en la plataforma Thingspeak.

La tasa o frecuencia de muestreo es el número de muestras por unidad de tiempo que se toman de una señal continua para producir una señal discreta, durante el proceso para convertirla de analógica en digital, según el teorema de muestreo de Nyquist-Shannon, se requiere que dicha señal sea muestreada al menos dos veces su frecuencia máxima ($60[Hz]$ en nuestro caso). La tasa de muestreo máxima en el Arduino es aproximadamente de $10,000 [Hz]$, lo cual es mucho mayor que $2 * 60[Hz]$.

Finalmente se toman varios valores para poder calcular la corriente y el voltaje RMS's, estos datos son mandados con su huella de tiempo por medio del protocolo MQTT a la plataforma Thingspeak, y por medio de una llave de escritura se guardan en la nube, posteriormente estos datos pueden ser bajados en un archivo CSV (Fig. 67).

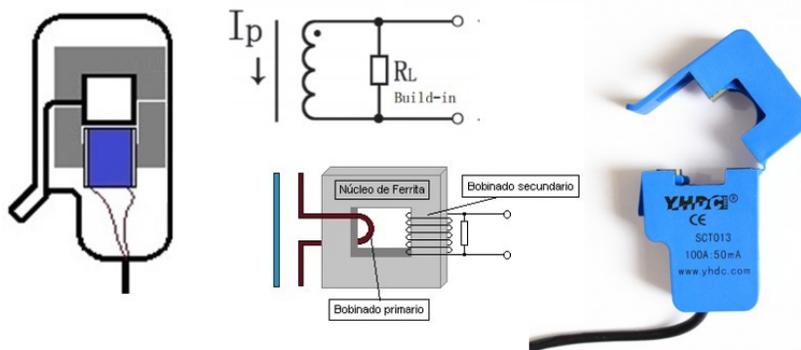


Figura 68: Sensor de Corriente Alternada no invasivo (SCT-030).

En este dispositivo se utilizó un sensor de corriente no invasivo (Fig. 68). El sensor (SCT-030) funciona mediante el fenómeno de inducción electromagnética, este sensor según su hoja de especificaciones puede medir corriente alterna en un rango de: 0 – 30 [A], arrojando una onda de voltaje DC en rangos de: -1 a 1 [V], (ver Cuadro 12).

Cuadro 12: Características del sensor SCT-030

$I_{entrada}$ [A]	V_{Salida} [V]	$T_{operación}$ [C]
0 - 30	-1 a 1	-25 a 70

Parámetros del sensor SCT-030.

En cuanto al sensor de voltaje AC, se usó el modelo ZMPT101B (Fig. 69), este sensor incorpora la electrónica necesaria para añadir un offset a la señal de salida, este offset se puede modificar con el trimpot añadido en el sensor. Como se puede apreciar en la Fig. 69, de un lado se conecta el voltaje AC a medir y por el otro tenemos la señal de salida (V_{out}) que va a una de las entradas analógicas del Arduino, un voltaje Vcc de 5 volts, el cual es necesario para funcionar y la tierra. Para sus características eléctricas ver Cuadro 13.

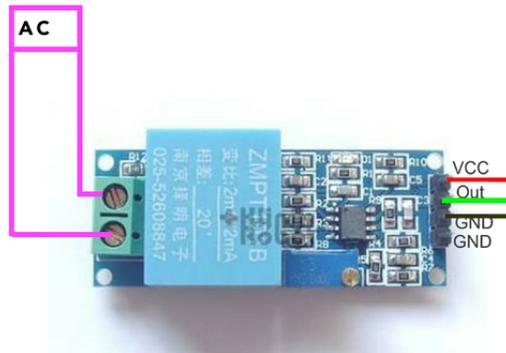


Figura 69: Sensor de Voltaje AC (ZMPT101B).

Cuadro 13: Características del sensor ZMPT101B

$V_{entrada}$ [V _{RMS}]	V_{Salida} [V _{DC}]	$T_{operación}$ [C]
0 - 250	0 a 5	-40 a 60

Parámetros del sensor ZMPT101B.

Finalmente el circuito electrónico propuesto ⁴ para el medidor de potencia basado en hardware libre encaminado al internet de las cosas (IoT) se muestra en la Fig. 70.

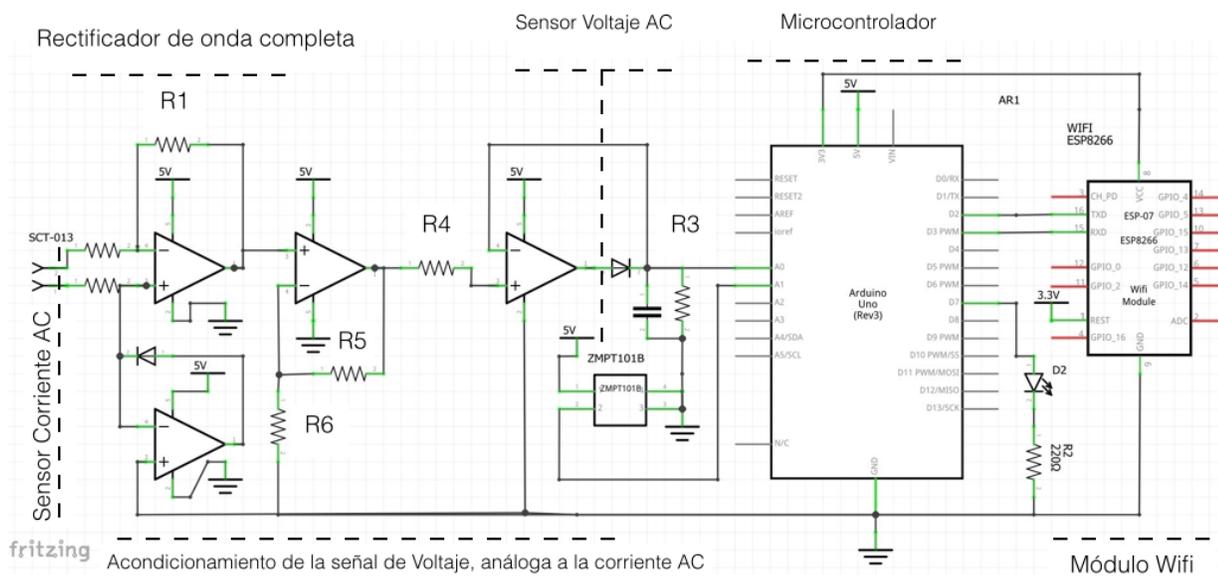


Figura 70: Circuito propuesto para el medidor de potencia.

⁴Véas el Apéndice B para reproducir el PCB del circuito.

Datos recolectados

Finalmente se instrumentaron 7 medidores de este tipo, en el Cuadro 14 se muestran los diferentes lugares donde se instalaron los medidores y sus características. En la Fig. 71 podemos apreciar algunos días de mediciones de potencia de generación FV.

Cuadro 14: Medidores instalados

Tipo	Municipio	Capacidad [KW]
Generador	Temixco	2 KW
Generador	Temixco	2 KW
Consumidor	Temixco	N/A
Prosumidor	Temixco	1 KW
Consumidor	Cuernavaca	N/A
Prosumidor	Cuernavaca	1 KW
Prosumidor	Cuernavaca	2 KW

Medidores instalados en los municipios de Cuernavaca y Temixco.

Para calibrar los medidores, al instalarlos, se utilizó una pinza amperímetro modelo UT202, el cual cumple con el estándar IEC61010.

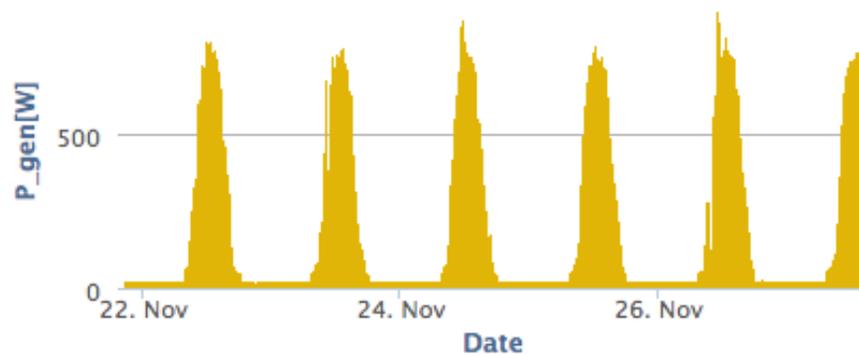


Figura 71: Potencia Generada [KW] por un Prosumidor.

También se recabaron datos de consumo eléctrico (Fig. 72), estos medidores estarán funcionando por un tiempo necesario para recolectar datos suficientes para crear modelos de predicciones de generación y demanda. Y así entender las dinámicas de futuras transacciones energéticas en micro redes con generación distribuida.

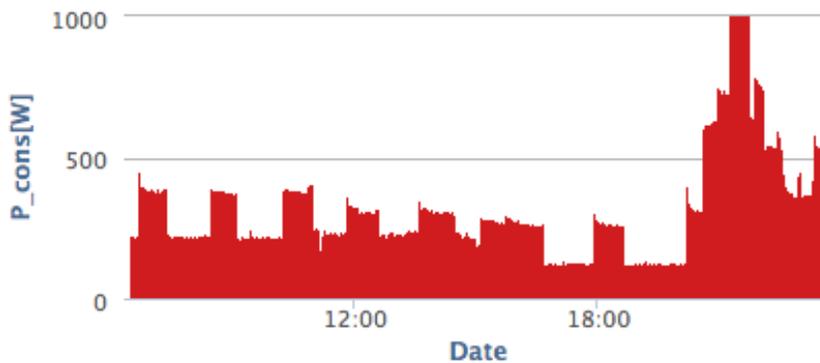


Figura 72: Potencia Consumida [KW] por un Consumidor.

Propuesta para conmutación de cargas de forma remota

La digitalización de la red eléctrica y el uso eficiente de la energía implica poder diseñar sistemas que puedan conmutar ciertas cargas domésticas (como lavadoras, lavaplatos, autos eléctricos, etc) en base a una señal de precio del mercado eléctrico mayorista (PML en el caso mexicano). Estas herramientas junto con sistemas de predicción pueden llegar a tener un impacto en términos de ahorro energético para prosumidores así como para la empresa suministradora.

Este segundo dispositivo está orientado a controlar cargas de manera remota, en la Fig. 73 se muestra el circuito electrónico, este circuito funciona con un Arduino Uno, al cual por medio de Internet se le puede programar para que mande una señal por una de sus salidas digitales al optoacoplador (MOC3031). El optoacoplador es un dispositivo de estado sólido que funcionará como una protección entre la parte de DC y la de AC. Dentro del optoacoplador podemos encontrar un fotodiodo el cual satura un fototransistor y este a su vez, satura o no la compuerta de un MOSFET (40 [A]). De esta forma el MOSFET funciona como un relevador de estado sólido y controla por medio de DC, la conmutación de cargas en AC (hasta 40 [A]). Cabe resaltar que la interconexión de cargas puede generar problemas en la red en cuanto a la calidad de la energía, el cual es un aspecto importante a considerar [22].

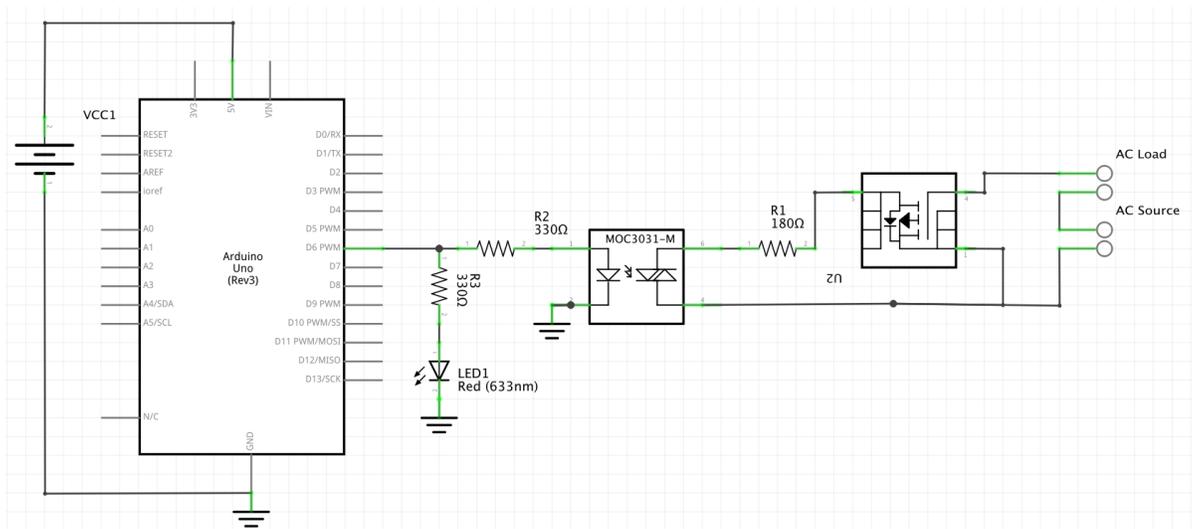


Figura 73: Circuito electrónico para conmutar cargas AC de manera remota.

Apéndice B - Circuitos electrónicos para el medidor de potencia activa.

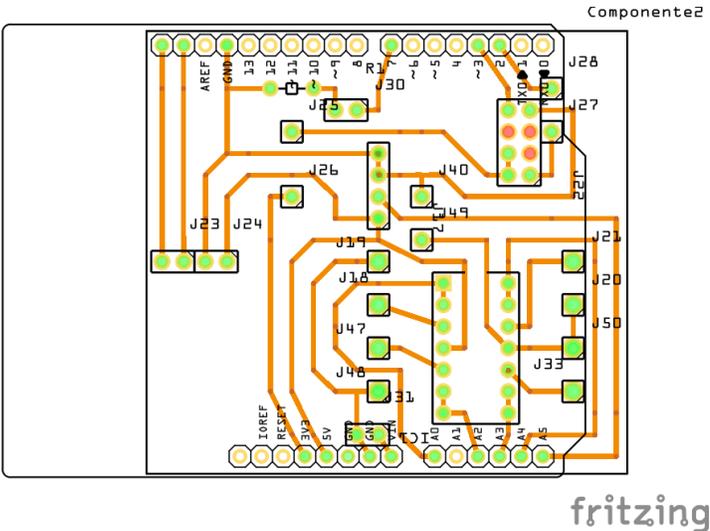


Figura 74: Circuito electrónico PCB para medidor de potencia activa IoT.

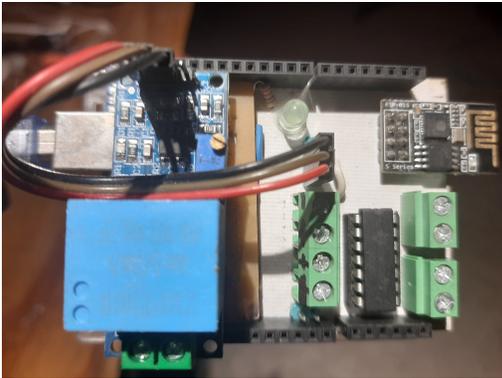


Figura 75: Medidor de potencia activa IoT.

Bibliografía

- [1] Huangjie Gong, Vandana Rallabandi, Michael L. McIntyre, Eklas Hossain, and Dan M. Ionel. Peak reduction and long term load forecasting for large residential communities including smart homes with energy storage. *IEEE Access*, 9:19345–19355, 2021.
- [2] Hyung Jun Moon, Seok Jun Bu, and Sung Bae Cho. Learning Disentangled Representation of Residential Power Demand Peak via Convolutional-Recurrent Triplet Network. *IEEE International Conference on Data Mining Workshops, ICDMW*, 2020-Novem:757–761, 2020.
- [3] Sternkopf Benjamin and Pesnel Pierre. Electrical Energy Storage in Mexico. *Deutsche Gesellschaft für Internationale Zusammenarbeit (GIZ)*, 1:6–12, 2019.
- [4] Christoph Heilmann and David Wozabal. How much smart charging is smart? *Applied Energy*, 291(February):116813, 2021.
- [5] Peng Kou, Deliang Liang, and Lin Gao. Distributed EMPC of multiple microgrids for coordinated stochastic energy management. *Applied Energy*, 2016.
- [6] Huai Su, Lixun Chi, Enrico Zio, Zhenlin Li, Lin Fan, Zhe Yang, Zhe Liu, and Jinjun Zhang. An integrated, systematic data-driven supply-demand side management method for smart integrated energy systems. *Energy*, 235:121416, 2021.
- [7] Comisión Federal de Electricidad (CFE). Estadísticas por regiones de transmisión. *México*, Available: <http://www.cfe.gob.mx/ConoceCFE/1AcercadeCFE/Estadisticas/>, Consulted : March2021.

- [8] Secretaría de Energía (SENER-SIE). Sistema de información energética, estadísticas energéticas nacionales. *Mexico, 2018*, Available: <http://sie.energia.gob.mx/>, Consulted: February 2021.
- [9] Carlo Brancucci Martinez-Anido. Renewable integration study baja california sur (baja-ris). *21st CPP Steering Committee Meeting, Ciudad de México, 27 de Septiembre del 2016*.
- [10] Ling Zheng, Bin Zhou, Siu Wing Or, Yijia Cao, Huaizhi Wang, Yong Li, and Ka Wing Chan. Spatio-temporal wind speed prediction of multiple wind farms using capsule network. *Renewable Energy*, 175:718–730, 2021.
- [11] Instituto Nacional de Electricidad y Energías Limpias (INEEL). Cemie – redes, el mercado eléctrico y las redes eléctricas inteligentes. *INEEL, 2018*, Disponible en: https://www2.ineel.mx/taller_redes/documentos/pdf/Mesa1_tema_antecedente_preguntas.pdf, Consultado en Febrero de 2019.
- [12] Secretaría de Energía (SENER). Beneficios de la generación distribuida y la eficiencia energética en México. *México, 2015*, Disponible en: <https://www.gob.mx/sener/documentos/beneficios-de-la-generacion-limpia-distribuida-y-la-eficiencia-energetica-en-mexico>, Consultado en Octubre de 2019.
- [13] Wencong Su, Jianhui Wang, Senior Member, and Jaehyung Roh. Stochastic Energy Scheduling in Microgrids With. 5(4):1876–1883, 2014.
- [14] Shahab Bahrami and M Hadi Amini. A Decentralized Framework for Real-Time Energy Trading in Distribution Networks with Load and Generation Uncertainty. pages 1–8.
- [15] Esther Mengelkamp, Scott Kessler, Johannes Gärttner, Kerstin Rock, Lawrence Orsini, and Christof Weinhardt. Designing microgrid energy markets. *Applied Energy*, 210:870–880, 2017.
- [16] Seyed Amir Alavi, Mehrnaz Javadipour, and Kamyar Mehran. State Monitoring for Situational Awareness in Rural Microgrids Using the IoT Infrastructure.
- [17] Secretaría de Energía (SENER-PRODESEN2020). Programa de desarrollo para el sistema eléctrico nacional 2020 - 2034. *México, 2020*, Disponible en: <https://www.gob.mx/sener/acciones-y-programas/>

- programa-de-desarrollo-del-sistema-electrico-nacional-33462, Consultado en Enero de 2020.
- [18] Kate Hawley Bunker, Kaitlyn and Jesse Morris. Renewable microgrids: Profiles from islands and remote communities across the globe. *Rocky Mountain Institute*, Disponible en: <http://www.rmi.org/islands-renewable-microgrids>, Noviembre 2015.
- [19] Zhaoxi Liu, Qiuwei Wu, Shaojun Huang, and Haoran Zhao. Transactive Energy : A Review of State of The Art and Implementation.
- [20] Donald J Hammerstrom and Hung Ngo. A Transactive Network Template for Decentralized Coordination of Electricity. *2019 IEEE PES Transactive Energy Systems Conference (TESC)*, pages 1–5, 2019.
- [21] Muhammad Raisul Alam, Marc St-Hilaire, and Thomas Kunz. Peer-to-peer energy trading among smart homes. *Applied Energy*, 238(December 2018):1434–1443, 2019.
- [22] Carson W. Taylor. Power system voltage stability. *Electric Power Research Institute*, McGraw Hill, pp.2-5, Apendix B, 2004.
- [23] Steve Widergren. A Society of Devices. (june), 2016.
- [24] Carsten Block, Dirk Neumann, and Christof Weinhardt. A Market Mechanism for Energy Allocation in Micro-CHP Grids. (May 2006):1–11, 2008.
- [25] Tianguang Lv and Qian Ai. Interactive energy management of networked microgrids-based active distribution system considering large-scale integration of renewable energy resources. *Applied Energy*, 163:408–422, 2016.
- [26] Marcus Meisel, Lampros Fotiadis, Stefan Wilker, Albert Treytl, and Thilo Sauter. Blockchain Applications In Microgrids. *Ieee*, pages 6153–6158, 2017.
- [27] Wessam El-baz, Peter Tzscheutschler, and Ulrich Wagner. Integration of energy markets in microgrids : A double-sided auction with device-oriented bidding strategies. *Applied Energy*, 241(November 2018):625–639, 2019.
- [28] Andrea Monacchi and Wilfried Elmenreich. Assisted energy management in smart microgrids. *Journal of Ambient Intelligence and Humanized Computing*, 7(6):901–913, 2016.

- [29] Centro Nacional de Control de Energía (CENACE). Sistema de información del mercado. *México, 2019*, Disponible en :[://www.cenace.gob.mx/MercadoOperacion.aspx](http://www.cenace.gob.mx/MercadoOperacion.aspx).
- [30] Comisión Reguladora de Energía (CRE). Generación distribuída (gd). *México*, Available: <https://www.gob.mx/cre/articulos/generacion-distribuida-102284>, Published: April 4th, 2017. Consulted: June 2021.
- [31] François Chollet. *Deep Learning with Python*. Manning, November 2017.
- [32] Jiaqi Qin, Yi Zhang, Shixiong Fan, Xiaonan Hu, Yongqiang Huang, Zexin Lu, and Yan Liu. Multi-task short-term reactive and active load forecasting method based on attention-LSTM model. *International Journal of Electrical Power and Energy Systems*, 135(August 2021):107517, 2022.
- [33] Hao Li, Zheng Xu, Gavin Taylor, and Tom Goldstein. Visualizing the loss landscape of neural nets. *CoRR*, abs/1712.09913, 2017.
- [34] Deepanshu Mehta. State-of-the-art reinforcement learning algorithms. *International Journal of Engineering and Technical Research*, V8, 01 2020.
- [35] Md. Zahangir Alom, Tarek Taha, Chris Yakopcic, Stefan Westberg, Paheding Sidi-ke, Mst Nasrin, Mahmudul Hasan, Brian Essen, Abdul Awwal, and Vijayan Asari. A state-of-the-art survey on deep learning theory and architectures. *Electronics*, 8:292, 03 2019.
- [36] Tae-young Kim and Sung-bae Cho. Predicting residential energy consumption using CNN-LSTM neural networks. *Energy*, 182:72–81, 2019.
- [37] Kejun Wang, Xiaoxia Qi, and Hongda Liu. Photovoltaic power forecasting based LSTM-Convolutional Network. *Energy*, 189:116225, 2019.
- [38] Jeff Donahue, Lisa Anne Hendricks, Sergio Guadarrama, Marcus Rohrbach, Subhashini Venugopalan, Kate Saenko, Trevor Darrell, U T Austin, Umass Lowell, and U C Berkeley. Long-term Recurrent Convolutional Networks for Visual Recognition and Description. pages 2625–2634, 2015.
- [39] Musaed Alhussein, Khursheed Aurangzeb, and Syed Irtaza Haider. Hybrid CNN-LSTM Model for Short-Term Individual Household Load Forecasting. *IEEE Access*, 8:180544–180557, 2020.

- [40] Tovar M. Rashid F., Robles M. PV Power Prediction, Using CNN-LSTM Hybrid Neural Network Model. Case of Study: Temixco-Morelos, México. *MDPI Energies*, 2020.
- [41] Danilo P. Mandic and Jonathon A. Chambers. Recurrent neural networks for prediction. *Wiley*, pp. 63 - 198., EUA, 2a Edición, 2009.
- [42] J. Koutnik B. Steunebrink J. Schmidhuber K. Greff, R. Srivastava. LSTM: A Search Space Odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 2016.), pages 1–7.
- [43] Shawn A Chandler and Joshua G Hughes. Smart Grid Distribution Prediction and Control Using Computational Intelligence. pages 86–89, 2013.
- [44] Malvern Madondo and Thomas Gibbons. Learning and Modeling Chaos Using LSTM Recurrent Neural Networks. *Proceedings of the Midwest Instruction and Computing Symposium*, 2018.
- [45] Rafael E Bourguet and Panos J Antsaklis. Artificial Neural Networks In Electric Power Industry. (April), 1994.
- [46] Robert Blaga, Andreea Sabadus, Nicoleta Stefu, Ciprian Dughir, and Marius Paulescu. A current perspective on the accuracy of incoming solar energy forecasting. *Progress in Energy and Combustion Science*, 70:119–144, 2019.
- [47] Reihaneh Haji, Mahdizadeh Zargar, Mohammad Hossein Yaghmaee, and Senior Member. Development of a Markov-Chain-Based Solar Generation Model for Smart Microgrid Energy Management System. 3029(c), 2019.
- [48] Min Gao, Kun Wang, and A Continuous-time Markov Chain. Probabilistic Model Checking for Green Energy Router System in Energy Internet. 2017.
- [49] Cyril Voyant, Gilles Notton, Soteris Kalogirou, Marie-laure Nivet, Christophe Paoli, Fabrice Motte, and Alexis Fouilloy. Machine learning methods for solar radiation forecasting : A review. *Renewable Energy*, 105:569–582, 2017.
- [50] Pilar Gómez-Gil, Juan Manuel Ramírez-Cortes, Saúl E. Pomares Hernández, and Vicente Alarcón-Aquino. A neural network scheme for long-term forecasting of chaotic time series. *Neural Processing Letters*, 33(3):215–233, 2011.

- [51] Mohamed Abdel-Nasser and Karar Mahmoud. Accurate photovoltaic power forecasting models using deep LSTM-RNN. *Neural Computing and Applications*, 31(7):2727–2740, 2019.
- [52] Ümmühan Ba and Tansu Filik. Wind Speed Prediction Using Artificial Neural Networks Based on Multiple Local Measurements in Eskisehir. 107(September 2016):264–269, 2017.
- [53] Zhuyi Rao and Yunxiang Zhang. Transformer-based power system energy prediction model. *Proceedings of 2020 IEEE 5th Information Technology and Mechatronics Engineering Conference, ITOEC 2020*, (Itoec):913–917, 2020.
- [54] Tuong Le, Minh Thanh Vo, Bay Vo, Eenjun Hwang, and Seungmin Rho. applied sciences Improving Electric Energy Consumption Prediction.
- [55] K Muralitharan, R Sakthivel, and R Vishnuvarthan. Neural Network based Optimization Approach for Energy Demand Prediction in Smart Grid AC PT US CR. *Neurocomputing*, 2017.
- [56] Yaguang Li, Rose Yu, Cyrus Shahabi, and Yan Liu. Diffusion convolutional recurrent neural network: Data-driven traffic forecasting. *6th International Conference on Learning Representations, ICLR 2018 - Conference Track Proceedings*, pages 1–16, 2018.
- [57] Power Predictions. Extreme Learning Machines for Solar Photovoltaic updated the. (Figure 1), 2018.
- [58] Xi Fang, Guangcai Gong, Guannan Li, Liang Chun, Pei Peng, and Wenqiang Li. A general multi-source ensemble transfer learning framework integrate of LSTM-DANN and similarity metric for building energy prediction. *Energy and Buildings*, 252:111435, 2021.
- [59] Qicheng Tang and Mengning Yang. ST-LSTM : A Deep Learning Approach Combined Spatio-Temporal Features for Short-Term Forecast in Rail Transit. 2019, 2019.
- [60] Antonello Rosato, Rodolfo Araneo, Amedeo Andreotti, Federico Succetti, and Massimo Panella. 2-D Convolutional Deep Neural Network for the Multivariate Prediction of Photovoltaic Time Series. *Energies*, 14(9):1–18, 2021.

- [61] Wei Li and Denis Mike Becker. Day-ahead electricity price prediction applying hybrid models of LSTM-based deep learning methods and feature selection algorithms under consideration of market coupling. *Energy*, 237:121543, 2021.
- [62] Ayush Sinha, Raghav Tayal, Aamod Vyas, Pankaj Pandey, and O. P. Vyas. Forecasting Electricity Load With Hybrid Scalable Model Based on Stacked Non Linear Residual Approach. *Frontiers in Energy Research*, 9(November):1–17, 2021.
- [63] Simran Kaur Hora, Rachana Poongodan, Rocío Pérez de Prado, Marcin Wozniak, and Parameshachari Bidare Divakarachari. Long short-term memory network-based metaheuristic for effective electric energy consumption prediction. *Applied Sciences (Switzerland)*, 11(23), 2021.
- [64] Bixuan Gao, Xiaoqiao Huang, Junsheng Shi, Yonghang Tai, and Jun Zhang. Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks. *Renewable Energy*, 162:1665–1683, 2020.
- [65] Dazhi Yang. A guideline to solar forecasting research practice: Reproducible, operational, probabilistic or physically-based, ensemble, and skill (ROPES). *Journal of Renewable and Sustainable Energy*, 11(2), 2019.
- [66] Tomoharu Iwata and Atsutoshi Kumagai. Few-shot Learning for Time-series Forecasting. pages 1–10, 2020.
- [67] Junseo Son, Yongtae Park, Junu Lee, and Hyogon Kim. Sensorless PV power forecasting in grid-connected buildings through deep learning. *Sensors (Switzerland)*, 18(8), aug 2018.
- [68] Ioannis Mexis and Grazia Todeschini. Battery energy storage systems in the united kingdom: A review of current state-of-the-art and future applications. *Energies*, 13(14), 2020.
- [69] S. B. T. Y., Cho. Predicting residential energy consumption using cnn-lstm neural networks. *Energy*, 182, 2019.
- [70] Bibi Ibrahim and Luis Rabelo. A deep learning approach for peak load forecasting: A case study on panama. *Energies*, 14(11), 2021.

- [71] Marija Zima-Bockarjova, Antans Sauhats, Lubov Petrichenko, and Roman Petrichenko. Charging and discharging scheduling for electrical vehicles using a shapley-value approach †. *Energies*, 13(5):1–21, 2020.
- [72] Mario Tovar, Miguel Robles, and Felipe Rashid. Pv power prediction, using cnn-lstm hybrid neural network model. case of study: Temixco-morelos, méxico. *Energies*, 13(24), 2020.
- [73] Tensorflow. Time series forecasting. *Advanced autoregressive model, 2022*, Available: https://www.tensorflow.org/tutorials/structured_data/time_series_advanced_autoregressive_model, *Cons January, 2022*.
- [74] journal = UK Energy volume = year = 2022 url = <https://es.catapult.org.uk/tools-and-labs/our-data/> CATAPULT Energy Systems, title = Visualizing the Loss Landscape of Neural Nets.
- [75] Mario A. Tovar Rosas, Miguel Robles Pérez, and E. Rafael Martínez Pérez. Itineraries for charging and discharging a bess using energy predictions based on a cnn-lstm neural network model in bcs, mexico. *Renewable Energy*, 188:1141–1165, 2022.
- [76] National Renewable Energy Laboratory. Solar dataset. *NREL, 2019*, Disponible en: <https://www.nrel.gov/solar/>, Consultado en Septiembre de 2019.
- [77] SAM NREL. System advisor model. *NREL Software*, Disponible en: <https://sam.nrel.gov/>, Consultado en Septiembre de 2019.
- [78] Antonello Rosato, Massimo Panella, Amedeo Andreotti, Osama A. Mohammed, and Rodolfo Araneo. Two-stage dynamic management in energy communities using a decision system based on elastic net regularization. *Applied Energy*, 291(February):116852, 2021.
- [79] Hugo T.C. Pedro, David P. Larson, and Carlos F.M. Coimbra. A comprehensive dataset for the accelerated development and benchmarking of solar forecasting methods. *Journal of Renewable and Sustainable Energy*, 11(3), 2019.
- [80] Arpad Gellert, Ugo Fiore, Adrian Florea, Radu Chis, and Francesco Palmieri. Forecasting Electricity Consumption and Production in Smart Homes through Statistical Methods. *Sustainable Cities and Society*, 76(April 2021):103426, 2022.

- [81] Tiago Pinto, Mohammad Ali Fotouhi Ghazvini, Joao Soares, Ricardo Faia, Juan Manuel Corchado, Rui Castro, and Zita Vale. Decision support for negotiations among microgrids using a multiagent architecture. *Energies*, 11(10), 2018.
- [82] Ricky T. Q. Chen, Yulia Rubanova, Jesse Bettencourt, and David Duvenaud. Neural Ordinary Differential Equations. *NeurIPS*, 2nd Conference on Neural Information Processing Systems (NeurIPS 2018), Montréal, Canada.
- [83] David Domínguez-Barbero, Javier García-González, Miguel A. Sanz-Bobi, and Eugenio F. Sánchez-Úbeda. Optimising a microgrid system by deep reinforcement learning techniques. *Energies*, 13(11), 2020.
- [84] Stefano Leonori, Enrico De Santis, Antonello Rizzi, and F. M.Frattale Mascioli. Optimization of a microgrid energy management system based on a Fuzzy Logic Controller. *IECON Proceedings (Industrial Electronics Conference)*, pages 6615–6620, 2016.