



Universidad Nacional
Federico Villarreal

Vicerrectorado de
INVESTIGACIÓN

Facultad de Ingeniería Electrónica e Informática
Escuela Profesional de Ingeniería Mecatrónica

MODELADO DE OPTIMIZACIÓN DE LOS COSTOS DE
ENERGÍA EN LA RED RESIDENCIAL INTELIGENTE

Tesis para optar el Título Profesional de Ingeniero Mecatrónico

AUTOR

Zarate Perez, Eliseo Juan

ASESOR

Rodríguez Figueroa, José Julio

JURADO

*Solis Fonseca, Justo Pastor
Kaseng Solis, Freddy Lizardo
Flores Masias, Edward Jose*

Lima - Perú
2019

Dedicatoria

Eu dedico esse trabalho a K.O.F.

Agradecimientos

A la profesora Ana Lúcia Torres Seroa da Motta, PhD en *Environmental Design and Engineering* por la *Bartlett School Of Architecture And Planning* - Inglaterra, por su contribución con el desarrollo de la tesis.

Al profesor Dr. José Julio Rodríguez Figueroa por su orientación en el presente trabajo de titulación.

A Manuel Enrique Azpilcueta Vásquez, por su aporte en el presente trabajo.

A todos aquellos, que, aunque no citados nominalmente, contribuyeron directa e indirectamente a la ejecución de la tesis.

Resumen

La demanda de electricidad en el sector residencial está aumentando a nivel mundial. La optimización de los recursos energéticos mediante la adopción de sistemas alternativos puede generar soluciones para el mejor uso de estos recursos. El objetivo de este trabajo es crear un modelo de optimización para evaluar los recursos energéticos utilizados por los productores - consumidores residenciales, centrándose en sus costos de energía y evaluar la posibilidad de producir energía fotovoltaica (PV). Las variables utilizadas en el modelo de optimización son: (a) irradiación solar PV, (b) el precio estimado de la energía PV, (c) la potencia consumida; y (d) el precio de compra de la energía de la red. La variable (a) se obtuvo de la base de datos de la *National Renewable Energy Laboratory*. La variable (b) se estimó a partir de los costos asociados y la energía producida durante el tiempo de operación del sistema PV. Se utilizó un modelo de pronóstico para obtener los valores faltantes de ocho meses a partir de un registro de datos de cuatro meses para obtener la variable (c), mientras que la variable (d) se tomó de las tasas establecidas por la concesionaria. El modelado de optimización de los recursos energéticos del productor - consumidor dio como resultado una reducción del 16.7% en los costos anuales de electricidad, basado en el modelo de compensación de facturación neta de energía (NEB).

Palabras clave: generación distribuida; optimización energética; energía residencial, modelado inteligente de redes; sistemas fotovoltaicos.

Abstract

The demand for electricity in the residential sector is increasing worldwide. Optimizing energy resources by adopting alternative systems can generate solutions for the best use of these resources. The objective of this work is to create an optimization model for the energy resources consumed by residential prosumers by focusing on their energy costs and to evaluate the possibility of producing photovoltaic (PV) energy. The variables used in the optimization model are: (a) PV solar irradiation, (b) the estimated PV energy price, (c) the power consumed, and (d) the purchase price of grid energy. Variable (a) was obtained from the database of the National Renewable Energy Laboratory Variable (b) was estimated from the associated costs and energy produced during the system's duration. A forecast model was used to obtain the missing eight-month values from a four-month data record to obtain variable (c), while variable (d) was taken from the rates set by the concessionaire. The modeling of the optimized energy resources of the prosumer resulted in a 16.7% reduction in annual electricity costs, based on the net energy billing compensation model.

Keywords: distributed generation; energy optimization; residential energy; intelligent network modeling; photovoltaic systems.

Índice

I Introducción	11
1.1 Descripción del problema.....	11
1.2 Formulación del problema	13
1.2.1 Problema general.....	13
1.2.2 Problemas específicos.....	13
1.2 Antecedentes.....	14
1.3 Objetivos.....	18
- Objetivo General.....	18
- Objetivos Específicos.....	18
1.4 Justificación	18
II Marco Teórico	21
2.1 Bases teóricas sobre el tema de investigación.....	21
2.1.1 Modelado matemático.....	21
2.1.2 Optimización matemática.....	23
2.1.3 Herramientas y técnicas de solución.....	27
2.1.4 Métodos de solución aplicados a previsión.....	31
III Método	39
3.1 Tipo de investigación.....	39
3.2 Ámbito temporal y espacial.....	39
3.3 Variables	40
3.4 Población y muestra	41
3.5 Instrumentos	42
3.6 Procedimientos.....	43
3.6.1 Función Objetivo.....	43
3.6.2 Potencia consumida (P_{dem} , t), potencia generada PV (P_{pv} , t).....	44
3.6.3 Estimación del precio de energía de la concesionaria (M_{rede} , t).....	51
3.6.4 Estimación del costo de la energía PV (M_{pv} , t).....	53
3.7 Análisis de datos	59
IV Resultados	61
4.1 Previsión de la demanda de energía	61
4.1.1 Previsión para la demanda de energía (P_{carga} , t).....	62

4.2 Estimación del costo de energía PV ($M_{\text{solar, t}}$)	64
4.2.1 Producción anual de energía (E_{anual})	64
4.2.2 Producción de energía durante la vida útil del sistema PV (E_{total}).....	65
4.2.3 Cálculo de la inversión del capital (C_{inicial}).....	65
4.2.4 Costo nivelado de energía (LCOE).....	66
4.2.5 Retorno de la inversión.	67
4.3 Optimización de los costos de energía del productor - consumidor	69
4.3.1 Estudio de caso.	70
V Discusión de Resultados.....	76
VI Conclusiones.....	79
VII Recomendaciones.....	81
VIII Referencias	82

Lista de figuras

<i>Figura (2.1): Red neuronal Multilayer Perceptron (MLP) con dos capas ocultas.</i>	35
<i>Figura (2.2): Estructura del Self Organizing Maps.</i>	36
<i>Figura (2.3): Red neural artificial Hopfield.</i>	37
<i>Figura (3.1): Procedimiento para el modelado de la previsión.</i>	46
<i>Figura (3.2): Registro de temperatura e irradiación solar para la ubicación de la unidad consumidora evaluada.</i>	47
<i>Figura (3.3): Red de Feed-forward Multicapa utilizada para la previsión.</i>	48
<i>Fuente: Elaboración en base a información de empresas especializadas en el sector.</i>	55
<i>Figura (4.1): Arquitectura de la red neural Feed-Forward utilizada en este trabajo.</i>	62
<i>Figura (4.2): Demanda de energía medida y prevista para el período de un año.</i>	63
<i>Figura (4.3): Producción anual de energía PV para diferentes potencias instaladas.</i>	64
<i>Figura (4.4): Producción de energía durante la vida útil del sistema para diferentes potencias.</i>	65
<i>Figura (4.5): Costo inicial ($C_{inicial}$) para diferentes potencias de instalación (P_m).</i>	66
<i>Figura (4.6): Costo nivelado de energía (LCOE) con diferentes potencias instaladas.</i>	67
<i>Figura (4.7): La TIR y TIRM para diferentes potencias instaladas (P_m) con un incremento de precio de la energía eléctrica del 6% al año y con una tasa de interés (i) del 12%.</i>	68
<i>Figura (4.8): Costos horarios para un período optando la tarifa de simple medición de energía sin generación de energía PV.</i>	71
<i>Figura (4.9): Costos mensuales para la tarifa de medición simple cuando se opta la producción de energía PV.</i>	72
<i>Figura (4.10): Equilibrio energético de la demanda y producción de energía PV semanal evaluados con periodos de una hora.</i>	73
<i>Figura (4.11): Costos de la energía optando la tarifa 1E, y de la energía PV usada e inyectada con periodos de una hora.</i>	74

Lista de tablas

<i>Tabla (1). Tarifa residencial con simple medición de energía (zona Lima Norte).</i>	<i>52</i>
<i>Tabla (2). Precios unitarios de los dispositivos del sistema de generación PV [S/. kWh].....</i>	<i>55</i>
<i>Tabla (3). Resultados de la validación cruzada de K-fold y prueba de Ljung-Box para los valores obtenidos por medio de las previsiones de la demanda energética.....</i>	<i>63</i>

Capítulo I

I Introducción

1.1 Descripción del problema

Con la invención de la energía de corriente alterna (AC) de alto voltaje, a finales del siglo XIX, la electricidad podría ser transmitida por grandes distancias a través de cables eléctricos (Hirsh, 1999). Esta producción masificada de energía AC fue ampliada, proyectada para transmitir continuamente la electricidad a los consumidores residenciales, comerciales e industriales. Por lo tanto, es incuestionable que el sistema centralizado de energía haya sostenido un crecimiento sin precedentes en el siglo XX (Adil & Ko, 2016).

Los signos de la decadencia en el siglo XXI de la forma de producir energía son cada vez más evidentes, como los conflictos crecientes de recursos ligados a combustibles fósiles, agotamiento de las reservas de combustibles tradicionales y cambios climáticos antropogénicos. Estos motivos mencionados ofrecen amplias razones para diseñar un sistema alternativo de energía que permita la deshabitación gradual de la dependencia de los combustibles fósiles, intensivos en carbono, para satisfacer las necesidades energéticas actuales y futuras del mundo. La solución hasta hoy ha sido a menudo aumentar la generación de energía y actualizar la infraestructura de red (ASCE, 2017).

Se necesitan enfoques innovadores para atender las necesidades de los millones de personas que requieren de electricidad, mientras que al mismo tiempo se hace la transición a un sistema de energía limpio y libre de carbono. En la actualidad hay evidencias de que la electrificación por medio de las redes de energía descentralizadas proponen nuevas alternativas, sugiriendo un cambio de paradigmas en la forma en que la energía es producida, entregada y consumida (Alstone, Gershenson, & Kammen, 2015).

Diversas opciones de políticas de fomento a la utilización de la energía renovable, especialmente con la energía PV, fueron consideradas a partir de la incertidumbre del petróleo en la década de 1970. Consecuentemente, veinte años después se introdujeron políticas de incentivo ligadas a la tarifa de energía eléctrica, como el *Feed-In-Tariff (FIT)*, el *Net Energy Metering (NEM)*, y últimamente el *Net Energy Billing (NEB)* (Pyrgou, Kylili, & Fokaidis, 2016). La FIT se refiere con las tarifas determinadas con acuerdos a largo plazo para el suministro de energía a través de fuentes renovables, establecido en unidades monetarias por kWh (Couture & Gagnon, 2010).

La NEM es comúnmente conocida como la forma en que los usuarios de sistemas de generación distribuida compensan su consumo de electricidad, inyectando el excedente de energía en la red, que se establece como créditos para su posterior uso. Mientras que el NEB, capaz de fijar el flujo de electricidad también en dos direcciones, para registrar transacciones netas de energía entre una concesionaria y una unidad consumidora (Eid, Reneses Guillén, Frías Marín, & Hakvoort, 2014). La NEM fue el sistema de compensación optado inicialmente por Perú, a través de la generación distribuida para autoconsumo por medio del Decreto Legislativo N° 1221.

Sin embargo, el Ministerio de Energía y Minas (MINEN), mediante Resolución Ministerial N° 292-2018-MEN/DM - 2018, hace una pre publicación del Decreto Supremo que aprueba el reglamento de la generación distribuida en el Perú con sus nuevas normativas, introduciendo la medición líquida para registrar transacciones de energía entre una unidad consumidora y la concesionaria (Francisco Ismodes Mezzano, 2018). En ese sentido, el reglamento de generación distribuida propuesta por el MINEN comprende dos escalas para generar energía renovable por medio de ese sistema; la primera denominada Mediana Generación Distribuida con capacidad mayor a 200 kW y

menor o igual a 10 MW, la segunda denominada Microgeneración Distribuida con capacidad máxima de 200 kW (D.L No. 1221, 2015).

Con ese nuevo reglamento (NEB) que se introduce en el sistema energético peruano, es de suma importancia los beneficios que podrían presentar las redes de energía inteligente para los actuales consumidores de energía. El actual consumidor es conceptualizado en el sistema energético como un elemento pasivo, y por medio de la generación de energía sustentable, el mismo consumidor se convertiría en un componente activo, y como consecuencia, tomaría el control de sus costos de energía, además, permitiendo de esa forma la deshabitación gradual de los combustibles fósiles.

1.2 Formulación del problema

1.2.1 Problema general.

De lo expuesto anteriormente nos preguntamos:

¿Cuáles serían los resultados al realizar el modelado de optimización del productor - consumidor de energía residencial en la red eléctrica inteligente por intermedio de un modelo matemático de optimización en base a la modalidad Net Energy Billing - NEB?

1.2.2 Problemas específicos.

Ese problema general nos motiva a cuestionarnos otras interrogantes específicas como:

(i) ¿Cómo sería posible obtener los datos de la carga energética de la unidad consumidora utilizando redes neurales artificiales para obtener el potencial solar PV?

(ii) ¿De qué manera se podría estimar el costo nivelado de la energía PV (LCOE)?

(iii) ¿Como se podría evaluar la posibilidad de producción de energía fotovoltaica Optimizando los recursos energéticos de un productor-consumidor residencial enfocando en los costos de su consumo de energía, (PV)?

1.2 Antecedentes

Thomas Edison desarrolló las primeras redes de iluminación en corriente directa (DC) alrededor de 1900, donde un pequeño generador de turbina de vapor servía a una base limitada de consumidores locales (Laloux & Rivier, 2013). La invención del transformador a fines del siglo XIX permitió aumentar los voltajes, permitiendo el transporte de electricidad de CA a larga distancia con pérdidas reducidas (Hammerstrom, 2007), produciéndose la centralización del sistema, basada en grandes centrales eléctricas por medio de combustibles fósiles (Laloux & Rivier, 2013).

Los primeros sistemas centrales de electricidad estaban típicamente integrados verticalmente. Un partido central, a menudo gubernamental, fue propietario, operó y administró las cuatro actividades del sistema de generación, transmisión, distribución y venta al consumidor final (Laloux & Rivier, 2013). El siglo XX marcó así la transición de las microrredes de propiedad y operación privadas, establecidas por empresas de servicios públicos competitivas, a grandes monopolios controlados por el gobierno. Este cambio en la propiedad y el control aceleraron la tendencia hacia la centralización de la red, el aumento de escala y el uso de combustibles fósiles, como el petróleo, el carbón y el gas, para la generación de electricidad (Batlle & Ocaña, 2013).

La crisis de los combustibles fósiles de la década de 1970 dio como resultado un aumento en los precios de los combustibles. Consecuentemente, las nuevas tecnologías

de generación de energía basadas en recursos energéticos alternativos, comenzaron a contribuir con la seguridad del suministro (Laloux & Rivier, 2013). Sin embargo, estas nuevas tecnologías aún estaban integradas en las topologías de red convencional. Pequeños productores de energía independientes surgieron para proporcionar un suministro de energía alternativa a una escala local más pequeña (Gómez, 2013).

Ello motivó a los investigadores a proponer modelos de optimización de los costos de la energía en base al consumidor final. Por ejemplo, Salpakari & Lund (2016) presenta, un modelo de optimización de costos del productor - consumidor con el objetivo de maximizar el autoconsumo fotovoltaico, en su artículo publicado en la revista *Applied Energy* [Energía Aplicada] titulado: “*Optimal and rule-based control strategies for energy flexibility in buildings with PV*”. [Estrategias de Control Óptimas Basadas en Reglas para la Flexibilidad Energética en Edificios con PV].

El modelo presentado por Salpakari & Lund (2016) analiza diferentes configuraciones del sistema durante un año completo, y utiliza datos empíricos del consumo de energía de un hogar en el sur de Finlandia. El resultado del trabajo consistió en obtener el control de costo óptimo empleando el precio de mercado por hora de la red de energía pública, logrando ahorros entre 13 y 25% en la factura anual de su consumo de electricidad.

De la misma forma, Ma, Liu, Zhang, Tushar, & Yuen (2016) en su trabajo de investigación disponible en la revista científica “*IEEE Transactions on Industrial Informatics*”. [*IEEE Transacciones en Informática Industrial*], titulado: “*Energy Management for Joint Operation of CHP and PV Prosumers Inside a Grid-Connected Microgrid: A Game Theoretic Approach*”. [Gestión de la Energía para la Operación Conjunta de CHP y el Productor - Consumidor FV dentro de una Microrred Conectada a la Red: Un Enfoque de la Teoría de Juegos], propone un modelo de optimización de

energía, el cual fue financiado por la Fundación Nacional de Ciencias Naturales de China, para la operación conjunta de los consumidores – productores de energía basada en el precio.

En particular, Ma et al., (2016) crea un modelo de optimización basado en el Stackelberg game, donde el operador de la Microred actúa como líder y los productores - consumidores de energía fotovoltaica son los seguidores. Para mencionado objetivo, se presentó el algoritmo heurístico basado en la evolución diferencial que puede ser adoptado por la Microred, y cada productor – consumidor puede adoptar una programación restringida no lineal para alcanzar el equilibrio de *Stackelberg*.

Por otro lado, Felix & Unsihuay-Vila (2018) en su investigación publicada en “2018 IEEE PES *Transmission & Distribution Conference and Exhibition - Latin America (T&D-LA)*”. [Conferencia y Exposición de Transmisión y Distribución IEEE PES 2018 - América Latina (T & D-LA)], titulado: “*A Model to optimize Mix Power Generation Selection of Distributed Renewable Plants for Expansion Planning with Reliability Criteria: An Application in Puno, Peru*”. [Un Modelo para Optimizar la Selección de la Generación de Energía de la Integración de Plantas Renovables Distribuidas para la Planificación de la Expansión con Criterios de Confiabilidad: una Aplicación en Puno, Perú], propone un enfoque matemático de optimización dinámica para obtener la combinación óptima de plantas de generación distribuida con recursos de energía renovable.

El modelo propuesto por Felix & Unsihuay-Vila (2018) toma como insumos el potencial energético de los recursos hídricos, eólicos y solares disponibles e inyectables en cada área; así como los parámetros de la red eléctrica existente y las plantas de generación convencionales. Además, el modelo propuesto utiliza las 8760 horas de un

año típico para analizar el de costo-sensibilidad aplicados para un caso real en el departamento de Puno, en el territorio peruano.

Finalmente, Villacorta, Kuong, & Mojonero (2018) presentan un trabajo reciente en el medio científico “*International Journal of Renewable Energy Research-IJREER*”. [Revista Internacional de Investigación de Energías Renovables-IJREER], titulado: “*Impact Assessment of Net Metering for Residential Photovoltaic Distributed Generation in Peru*”. [Evaluación de Impacto de la Medición neta para la Generación Distribuida Fotovoltaica Residencial en Perú], para evaluar el impacto técnico-económico del mecanismo de integración denominado medición neta (*Net Energy Metering - NEM*) para el usuario final y la compañía de distribución de electricidad, mediante la conexión de sistemas fotovoltaicos a la red de distribución en la ciudad de Arequipa, región del territorio peruano.

Villacorta et al., (2018), obtiene como resultado que la unidad consumidora residencial conectado a la red de electricidad con la tarifa BT5B y considerándolo productor de energía fotovoltaica, proporciona un fuerte incentivo económico para la instalación de sistemas fotovoltaicos optando por el sistema de medición neta, con un tiempo de recuperación de la inversión de 6 años, considerando que en la región analizada hay un alto nivel de irradiación solar.

Sin embargo, debido a la reciente introducción del sistema de facturación neta (*Net Energy Billing - NEB*), a nuestro entender, no se ha encontrado aun trabajos en el Perú que trate de evaluar el impacto de la reducción de costos de la energía con esa nueva modalidad que el consumidor – productor de energía podría optar por medio de la red inteligente. Por lo tanto, un modelado de optimización de energía permitiría evaluar y determinar con precisión la viabilidad de optar por el sistema NEB, en base a la reducción costo de la energía para el usuario final.

1.3 Objetivos

- **Objetivo General.**

Modelar la optimización de los recursos energéticos de un productor-consumidor residencial enfocando en los costos de su consumo de energía, evaluando la posibilidad de producción de energía fotovoltaica (PV).

- **Objetivos Específicos.**

- (i) Obtener el potencial solar PV;
- (ii) Estimar el costo nivelado de la energía PV (LCOE);
- (iii) Realizar el modelado de optimización del productor - consumidor residencial de energía en la red eléctrica inteligente por intermedio de un modelo matemático de optimización en base a la modalidad *Net Energy Billing* – NEB, con la finalidad de reducir sus costos.

1.4 Justificación

Las preocupaciones ambientales de reducir las emisiones de gases de efecto invernadero (GEI), conjuntamente con el agotamiento de las fuentes de energía no renovables, hacen que los países se comprometan en incentivar la generación de energía renovable para contribuir con ello la reducción de las emisiones de los contaminantes atmosféricos (Sastre, González-Arechavala, & Santos, 2015). La asociación de otros factores, como la creciente demanda de electricidad, incentivan aún más el proceso de sustitución de combustibles fósiles por energías renovables (Rabbani & Dolatkhah, 2018).

Desde el siglo XX, la energía eléctrica ha desempeñado un papel fundamental en el desarrollo humano, especialmente para el desarrollo social y económico. Sin embargo,

actualmente en el siglo XXI, debido al crecimiento exponencial económico, así como de la población mundial, y por la escasez de recursos energéticos convencionales, llevan a la necesidad de adoptar fuentes alternativas de energía (Bilgili, Ozbek, Sahin, & Kahraman, 2015). Por lo tanto, la preservación y continuidad de la red caracteriza, en el momento actual, muchos desafíos debido a las constantes incertidumbres entre la oferta y la demanda de energía eléctrica y ante todo debido a la intensa concentración de demanda en períodos típicos (Georgilakis & Hatziargyriou, 2013).

Los sistemas de energía eléctrica están experimentando cambios relevantes que involucran la creciente penetración de los sistemas de generación distribuida, la gestión de cargas sensibles, y las propuestas para nuevos mercados de energía. Dicha evolución está impulsando un cambio de paradigma que es uno de los desafíos más importantes en el diseño de redes eléctricas: la administración debe pasar de la planificación tradicional y la intervención manual al control inteligente de las redes de media y baja tensión (Ghiani et al., 2018).

En ese sentido, el NEB (*Net Energy Billing*), nuevo sistema de facturación de energía por medio de la generación distribuida que se introduce al sistema energético peruano puede ofrecer variados beneficios para los consumidores tradicionales de energía. Por lo tanto, realizar el modelado computacional de la red inteligente de energía, con los datos reales de consumo, es fundamental para comprender los beneficios que un productor – consumidor pueda obtener al participar como un componente activo en la red de energía inteligente por medio de la generación de energía sustentable.

Capítulo II

II Marco Teórico

2.1 Bases teóricas sobre el tema de investigación

En este capítulo se presenta la fundamentación teórica que respalda el modelado matemático del productor - consumidor residencial para su correspondiente análisis de la interacción en la red de energía inteligente. Se presenta el fundamento del modelo de gestión, y las redes neuronales artificiales para la previsión de demanda energética y potencia activa fotovoltaica. Finalmente se presenta la fundamentación teórica del cálculo del costo nivelado de energía PV.

El modelado de sistemas de energía distribuida ayuda a comprender su comportamiento y facilita el pronóstico, el desarrollo y la toma de decisiones de diseño. Las técnicas de programación matemática han demostrado ser herramientas adecuadas para evaluar los mejores diseños de sistemas de energía distribuida restringidos por parámetros específicos de la ubicación y de acuerdo con las normas de cada región o país. Se proporciona la base teórica sobre el modelado matemático y optimización y su aplicación al diseño sistemas de energía distribuida.

2.1.1 Modelado matemático.

La construcción de modelos implica observar un sistema y sus componentes analizándolo a través de una representación abstracta (Keirstead & Shah, 2013). Las representaciones abstractas emplean relaciones matemáticas, tales como ecuaciones y dependencias lógicas, para representar las relaciones internas y la estructura de un sistema (Williams, 2013). Por lo tanto, se requieren supuestos y simplificaciones de la realidad para reducir la cantidad de información detallada y el costo requerido para modelar un

sistema real, y para aumentar la aplicabilidad general del modelo (Keirstead & Shah, 2013).

Los problemas de diseño de sistemas eléctricos distribuidos son inherentemente complejos y grandes problemas combinatorios. No solo implican múltiples configuraciones alternativas y restricciones de diseño, sino también incertidumbres relacionadas con el diseño del modelo, el análisis del modelo y la interpretación de los resultados (Gamarra & Guerrero, 2015). Por lo tanto, el modelado de sistemas eléctricos distribuidos requiere un equilibrio entre la complejidad, la precisión y la solidez del modelo (Alarcon-Rodriguez, Ault, & Galloway, 2010).

El diseño de sistemas eléctricos distribuidos es un problema interdisciplinario integrado, que involucra escalas temporales y espaciales, gran cantidad de datos de entrada, recursos energéticos múltiples, tecnologías e interacciones energéticas, y la consideración de objetivos de diseño múltiples (Keirstead & Shah, 2013). La programación matemática proporciona aquí una herramienta adecuada para incorporar todos los aspectos anteriores en la identificación del diseño óptimo de sistemas eléctricos distribuidos (Gamarra & Guerrero, 2015).

La optimización se refiere a un grupo de técnicas matemáticas que intentan obtener decisiones o soluciones óptimas disponible hacia un objetivo de minimización o maximización establecido dentro de un dominio factible determinado por restricciones (Williams, 2013). La optimización requiere la identificación de objetivos, variables de decisión, parámetros determinados y restricciones que se aplican al sistema (Gamarra & Guerrero, 2015). Esto contrasta con los enfoques de simulación en los que el comportamiento real de

un sistema se analiza mediante un resultado descriptivo imitando al sistema real (Keirstead & Shah, 2013).

2.1.2 Optimización matemática.

La optimización ha recibido una atención cada vez mayor por los problemas de diseño debidos a los desarrollos en el poder computacional y las herramientas de solución, la elección del modelo y la optimización (Keirstead & Shah, 2013). El enfoque depende de la naturaleza del problema (Gamarra & Guerrero, 2015). Por lo tanto, es necesario revisar el planteamiento de los modelos de optimización y sus métodos de solución. Los modelos de optimización se pueden clasificar según su tipo de variables, no lineales, convexos u objetivos, como se detalla a continuación.

2.1.2.1 Clasificación del modelo basado en el tipo de variable y la no linealidad.

Las variables pueden definirse como continuas, es decir, capaces de tomar cualquier valor real dentro de un intervalo continuo especificado. Las variables discretas, en contraste, pueden tomar un valor de un conjunto finito de valores especificados, a menudo enteros. Las variables discretas que solo pueden tomar el valor 0 o 1, son variables binarias. Los modelos con solo variables continuas son problemas continuos y los modelos con solo variables discretas son problemas discretos (Williams, 2013). Los modelos que tienen ambos tipos de variables son problemas de enteros mixtos. La combinación de variables discretas y continuas permite tanto decisiones de selección (binarias) como operativas (continuas) (Floudas, 1995).

Las relaciones no lineales (y) entre las variables (x, z) conducen a modelos no lineales (por ejemplo, $y = x \cdot z$). Un problema con solo las relaciones lineales entre variables es un modelo lineal (por ejemplo, $y = x + z$) (Biegler & Grossmann, 2004). Los tipos de problemas más comúnmente empleados son problemas con solo variables continuas que pueden ser problemas de programación lineal (LP) o de programación no lineal (NLP); problemas con variables tanto continuas como discretas, como la programación entera mixta (MIP) que puede ser lineal (MILP) o no lineal (MINLP); y problemas con solo variables enteras, es decir, programación de enteros (IP) (Williams, 2013).

Un modelo MIP general está representado por la Ecuación 2.1 (Biegler & Grossmann, 2004). El objetivo Z , función de las variables x e y ($f(x, y)$), se minimiza sujeto a la igualdad lineal (MILP) o no lineal (MINLP) ($h(x, y)$) y la desigualdad ($g(x, y)$) restricciones continuas (x) y variables binarias (y):

$$\min_{x,y} Z = f(x, y) \text{ s.t. } \begin{cases} h(x, y) = 0 \\ g(x, y) \leq 0 \\ x \in X, y \in 0,1 \end{cases} \quad (2.1)$$

2.1.2.2 Clasificación del modelo en función de la convexidad.

Una segunda clasificación de modelo puede basarse en la convexidad. La función $f(x)$ es convexa sobre $x \in X$, para cualquier par de soluciones x_1 y x_2 , si algún punto entre el par de soluciones se basa en un factor de ponderación $\lambda \in [0, 1]$ ($\lambda \cdot x_1 + (1 - \lambda) \cdot x_2$) tiene un valor de

función $(f(\lambda \cdot x_1 + (1 - \lambda) \cdot x_2))$ más pequeño o igual al punto equivalente entre los valores de función del par de soluciones en función del mismo factor de ponderación $(\lambda \cdot F(x_1) + (1 - \lambda) \cdot f(x_2))$ (Deb, 2001):

$$f(\lambda x_1 + (1 - \lambda)x_2) \leq \lambda f(x_1) + (1 - \lambda)f(x_2) \quad (2.2)$$

Un problema convexo tiene una región factible convexa (Floudas, 1995). Los modelos lineales son inherentemente convexos. Para modelos estrictamente convexos, existe una única solución óptima, es decir, una optimalidad global alcanzable. Los problemas no convexos presentan el riesgo de alcanzar una solución / solución óptima local y no alcanzar el nivel global. Por lo tanto, los problemas no convexos requieren procedimientos de solución más elaborados para alcanzar potencialmente una optimalidad global (Williams, 2013).

2.1.2.3 Clasificación del modelo basado en el tipo de datos de entrada.

El tipo de datos de entrada determina si el problema es determinista o estocástico. Los problemas deterministas suponen que los parámetros de entrada se conocen con precisión. Sin embargo, la incertidumbre que rodea estas entradas de valor fijo puede afectar los resultados. La incertidumbre surge debido a la previsión o elección de un valor único de un intervalo cambiante. La optimización estocástica, también denominada optimización bajo incertidumbre, tiene en cuenta este parámetro de incertidumbre. Aquí se pueden emplear valores generados aleatoriamente o funciones de

densidad de probabilidad, lo que lleva a una solución que satisface un rango de entradas (Williams, 2013).

2.1.2.4 Modelo de clasificación en función del número de objetivos.

La mayoría de los problemas de diseño son inherentemente multiobjetivo. La determinación de la solución óptima requiere un compromiso entre múltiples objetivos (a menudo en conflicto) con $i \in [1; n]$ (Alarcon-Rodriguez et al., 2010):

$$\min_{x,y} = [f_1(x, y); f_2(x, y); \dots; f_n(x, y)] \text{ s.t. } \begin{cases} h(x, y) = 0 \\ g(x, y) \leq 0 \\ x \in X, y \in 0,1 \end{cases} \quad (2.3)$$

A diferencia de los problemas de un solo objetivo, los problemas de múltiples objetivos no conducen a una única solución óptima, sino a un conjunto de soluciones óptimas (Alarcon-Rodriguez et al., 2010). Los problemas de objetivos múltiples apuntan a construir la llamada curva de compensación de Pareto de soluciones no dominadas entre objetivos, un conjunto discreto de soluciones en la curva, o, un conjunto de Pareto. Una solución no está dominada y pertenece al conjunto de Pareto de un problema si no se puede mejorar con respecto a un objetivo sin empeorar en otro objetivo (Deb, 2001).

Las soluciones de Pareto deben seleccionarse en función de la precisión (soluciones no dominadas), la diversidad (diversamente en el frente) y la dispersión (puntos de captura en toda la curva, incluidos los extremos) (Alarcon-Rodriguez et al., 2010). La mejor compensación entre

objetivos múltiples es una decisión subjetiva (Deb, 2001). El mejor punto a menudo estará en un punto de inflexión donde se obtiene un mayor retorno de un objetivo. Un conjunto de Pareto se construye entre soluciones extremas que se obtienen a través de la optimización de un solo objetivo a la vez. (Belegundu; & Chandrupatla, 2011).

2.1.3 Herramientas y técnicas de solución.

Después del desarrollo del modelo, se debe seleccionar una herramienta de optimización y un software adecuado. El software de optimización, como (GAMS, 2018) o AMPL (Fourer, Gay, & Kernighan, 1990), se utiliza para formular simbólicamente el problema y analizar soluciones basadas en un conjunto de entradas. Se tiene también el software “R Core Team” con variados *packages* para la solución de problemas de optimización. La mayoría del software tiene acceso a varios solucionadores que utilizan un determinado método de solución (R Core Team; 2018).

2.1.3.1 Métodos de solución deterministas.

Los métodos deterministas se basan tradicionalmente en enfoques de búsqueda directa, gradientes y funciones diferenciables (Keirstead & Shah, 2013). Existen múltiples métodos de soluciones bien desarrolladas para programas lineales que pueden tratar problemas complejos con muchas variables y restricciones (Biegler & Grossmann, 2004). Uno de los enfoques deterministas más comunes y poderosos para resolver problemas lineales (LP) en un número finito de pasos es el método Simplex (Williams, 2013).

Los métodos de solución MILP utilizan principalmente un método de búsqueda de árbol basado en ramas y enlaces (Dakin, 1965). El método

de ramificación y límite construye un árbol basado en variables binarias, que sistemáticamente divide el problema en problemas secundarios con una solución basada en una combinación de valores de variables binarias (Floudas, 1995). Otros métodos son el plano de corte y los métodos de descomposición (Biegler & Grossmann, 2004).

El método de Plano de corte introduce nuevas restricciones (recortes), en lugar de problemas secundarios, para reducir la región factible hasta que se alcance la optimización. Los métodos de descomposición utilizan la división de la región factible en subdivisiones, conceptos de dualidad para explotar la estructura matemática inherente del problema (Floudas, 1995). CPLEX y GUROBI son solucionadores comunes para problemas MILP (NEOS Server, 2018).

Los métodos deterministas para los modelos no lineales incluyen algoritmos basados en pasos de Newton que requieren múltiples iteraciones, incluidos los métodos de conjunto activo y punto de barrera / interior, la explotación de información de segundo orden a través de herramientas de diferenciación automática y los métodos de región lineal frente a confianza para mejorar la convergencia según los puntos de partida (Biegler & Grossmann, 2004). Los métodos de solución para el MINLP incluyen y el método de aproximación externa analiza la estructura del modelo a través de un proceso iterativo y un enfoque basado en ramas y límites. Los solucionadores de PNL populares (MI) son ALPHAECP, ANTIGONE, SBB, entre otros (NEOS Server, 2018).

2.1.3.2 Métodos de solución estocástica.

Los enfoques estocásticos se centran en la generación aleatoria y están inspirados en procesos físicos que generan puntos para converger a un equilibrio (Grossmann & Biegler, 2004). Los métodos de solución estocástica aproximan soluciones globales por medio de algoritmos de aproximación. Un ejemplo de enfoques estocásticos incluye los métodos clásicos de búsqueda directa, a menudo basados en heurísticas, y una generalización de los métodos heurísticos, es decir, los métodos meta-heurísticos (Gamarra & Guerrero, 2015).

Los métodos de solución heurística son procedimientos simples que buscan encontrar una solución satisfactoria a partir de un gran conjunto de soluciones factibles de problemas a menudo complejos, pero no necesariamente obtienen la solución óptima (Baños et al., 2011). Estos métodos de aproximación requieren menos esfuerzo computacional que los métodos deterministas (Gamarra & Guerrero, 2015). Los métodos metaheurísticos tienen como objetivo encontrar una solución dentro de un espacio de búsqueda discreto y, por lo tanto, combinar múltiples métodos heurísticos. Los métodos meta-heurísticos están inspirados en los procesos naturales y comenzaron su desarrollo en los años 1980-1990 (Fathima & Palanisamy, 2015).

Los métodos de solución basados en la trayectoria, por ejemplo, obtienen una solución única a lo largo del proceso de búsqueda. La mayoría de los métodos basados en la trayectoria siguen procedimientos basados en la mejora iterativa de movimientos junto con técnicas para alejarse de los óptimos locales (Baños et al., 2011). Algunos ejemplos de métodos de

solución basados en la trayectoria son el recocido simulado, la escalada en pendientes y la búsqueda de tabúes (Erdinc, Uzunoglu, Erdinc, & Uzunoglu, 2012).

2.1.3.3 Métodos de solución Multiobjetivo.

Se puede obtener un conjunto de problemas Multiobjetivo a través de los llamados enfoques clásicos por medio del método de Pareto, como la suma ponderada y el método de restricción o los enfoques basado en algoritmos evolutivos (Deb, 2001). Los enfoques clásicos, o los enfoques deterministas, por lo general convierten los objetivos múltiples en un solo problema objetivo, ya sea combinando los objetivos en una suma ponderada, o resolviendo una optimización objetiva única con restricciones de desigualdad adicionales para el otro objetivo (Pokharel, Mokhtar, & Howe, 2012).

Con el enfoque de la suma ponderada, los pesos de los objetivos se cambian de forma iterativa para obtener un conjunto del tipo de Pareto. El método construye un conjunto de Pareto basado en cambios iterativos del objetivo restringido. Los enfoques clásicos son directos en la aplicación. Sin embargo, el enfoque de suma ponderada solo es confiable para problemas convexos ya que los cambios en los frentes de Pareto no convexos podrían ser no capturados. Además, el enfoque de suma ponderada se vuelve complejo para un gran número de objetivos. El método de restricción, además, requiere una selección cuidadosa para obtener soluciones viables (Deb, 2001).

2.1.4 Métodos de solución aplicados a previsión.

Los modelos de previsión de energía son esenciales para la toma de decisiones en el sector energético. El desarrollo de estos modelos tomó interés tras la crisis del petróleo en la década de 1970, debido a los efectos de la dependencia de fuentes convencionales de combustible en la economía global (Rabbani & Dolatkah, 2018). Los modelos tradicionales se encuentran en la literatura en base a series temporales y modelos basados en regresión y econometría. Otro grupo de previsiones presenta las técnicas computacionales como redes neuronales artificiales, lógica *fuzzy*, algoritmos genéticos, y modelos de regresión vectorial de soporte (de Oliveira & Cyrino Oliveira, 2018).

Un trabajo de revisión se puede encontrar en (Shao, Chao, Yang, & Zhou, 2017), dedicado a la identificación de enfoques basados en descomposición de series temporales para la previsión de carga eléctrica, en donde se discuten la clasificación y características de la previsión de demanda, así como la característica única de fluctuación de la demanda de electricidad en diferentes escalas de tiempo. Otro trabajo de revisión es presentada por (Kuster, Rezgui, & Mourshed, 2017), en la que se identifican tres enfoques principales en términos de notoriedad; modelos de series temporales, formulaciones basadas en regresión y redes neuronales artificiales.

Una más reciente revisión de varios métodos de planificación energética realizado por (Kuster et al., 2017), reveló el uso de más de cincuenta métodos diferentes entre los años 1980 a 2017. Entre ellos, se tiene 28 métodos estadísticos, 21 métodos de inteligencia computacional y 1 en base a

programación matemática. En el caso de los métodos estadísticos, 46 métodos de media móvil integrada autorregresiva (ARIMA), 39 métodos de regresión lineal (RL) y 22 en base a media móvil autorregresiva (ARMA). Es evidente que los métodos de inteligencia computacional fueron regularmente utilizados en comparación con los estadísticos para previsión de carga eléctrica y energía renovable, en virtud de su mejor desempeño.

La previsión de la demanda de energía permiten diversas aplicaciones de gestión y eficiencia que dan soporte a la planificación, para consecuentemente, lograr la optimización de sistemas de energía distribuida (Jain, Smith, Culligan, & Taylor, 2014). Los modelos de red neuronal artificial (RNA) se utilizan para predecir la demanda de electricidad, así como la producción de energía PV debido a su buen desempeño (Hyndman & Athanasopoulos, 2014). Sin embargo, existen diferentes generaciones de redes neuronales que han ido desarrollándose de acuerdo con las necesidades u objetivos de los investigadores o los problemas a resolver, entre ellas se mencionan a continuación.

La primera generación de RNA se desarrolló en base en las neuronas limítrofes que generan salidas binarias (McCulloch & Pitts, 1943). Esta generación de RNA se modela con entradas decimales para obtener salidas digitales. Ya las neuronas de segunda generación se implementaron con entradas y salidas analógicas, utilizando una función de activación continua para calcular su salida. Entre las mencionadas funciones de activación se tiene la función sigmoide e hiperbólica (Maass, Schmitz, & Sontag, 1991). Por ello, las neuronas de la segunda generación son consideradas una aproximación más

cercana de las neuronas biológicas. Estas neuronas artificiales presentan un mejor desempeño con la generación antecesora (Dasgupta & McGregor, 1992).

La tercera generación de redes neuronales genera picos de salida individuales estando aún más cerca de las neuronas biológicas. Esta generación se denomina redes neuronales de *Spiking* (SNN) (Ferster & Spruston, 1995). En la literatura, resultados experimentales muestran que las neuronas de la corteza cerebral pueden realizar cálculos analógicos a una alta velocidad. Si, por ejemplo, la clasificación de entradas visuales del ser humano ocurre por debajo de 100 ms, lo que se considera como un período muy corto para calcular y procesar la información, esta generación de redes neuronales artificiales se aproxima a ello. Así, siempre que la velocidad sea un problema para la solución del objetivo, los esquemas de redes neuronales de *Spiking* son considerados los mejores (Bystron, Rakic, Molnár, & Blakemore, 2006).

A vista del avance significativo en esta área, las RNAs se utilizan en diferentes aplicaciones prácticas como en previsión de series temporales, reconocimiento de patrones, clasificación, reconocimiento de secuencias, procesamiento de datos, diagnóstico médico, filtrado, agrupación, identificación y control de sistemas, aplicaciones financieras, visualización, entre otras aplicaciones (Khan, 2018). Sin embargo, se debe considerar su modo de operación y sus reglas de aprendizaje para elegir el tipo de red neural más adecuada de acuerdo con las necesidades de utilización.

Las redes neurales artificiales operan en dos fases en modo de aprendizaje denominado entrenamiento, o en el modo de validación. Para iniciar el aprendizaje, parte de un conjunto aleatorio de parámetros denominados pesos, ellos son continuamente actualizados hasta que la solución

deseada sea obtenida. Los parámetros se establecen y permanecen fijos durante el proceso de validación. Además, durante el proceso adaptativo de aprendizaje, los pesos entre todas las neuronas interconectadas se actualizan hasta que se alcanza un punto óptimo (Khan, 2018).

De igual forma, las reglas de aprendizaje son métodos usados para ajustar las cantidades responsables por las informaciones aprendidas por los pesos. Los principales mecanismos de aprendizaje están representados de dos maneras: supervisada y la no supervisada. El aprendizaje supervisado se aplica cuando un resultado de salida deseado se utiliza para orientar la actualización en los parámetros de la red neural artificial. En el mecanismo no supervisado, el entrenamiento de la red es totalmente dependiente de los datos de entrada y no hay previsión de los resultados de destino para actualizar los parámetros de red neuronal (Hinton, Osindero, Welling, & Teh, 2006).

Los métodos convencionales de aprendizaje son los denominados *Back-propagation* y los métodos evolutivos. En el *Back-propagation*, la salida y los resultados deseados se comparan y el error es realimentado para actualizar los pesos del modelo. En los métodos evolutivos, los pesos de mejor desempeño obtenidos por el modelo son ligeramente alterados para producir el siguiente conjunto de pesos (Khan, 2018). Entre los principales tipos de redes neurales artificiales que se han introducido en la literatura son la red neuronal de *feed-forward*, *Kohonen self-organizing map* y las redes neuronales *Hopfield*.

2.1.4.1 Red Neural de Feed-forward.

La red neural de *Feed-forward* es organizada en capas, donde cada capa tiene un número de neuronas como unidad de procesamiento. A través del modo de entrada-salida, las señales se transfieren de capa a capa. Esta

arquitectura de la red neuronal tradicional se denomina *Multilayer Perceptron* (MLP). Existen dos capas de elementos de procesamiento y una capa oculta en las redes MLP, en su forma estándar. Sin embargo, el número de capas ocultas puede variar de acuerdo a los ajustes de los parámetros de acuerdo a los datos de entrada (Khan, 2018).

La figura (2.1) presenta un esquema de un modelo general de la red MLP que consiste en una capa de entrada con tres entradas (E_1 , E_2 , y E_3), dos capas ocultas y una capa de salida con dos salidas (S_1 y S_2).

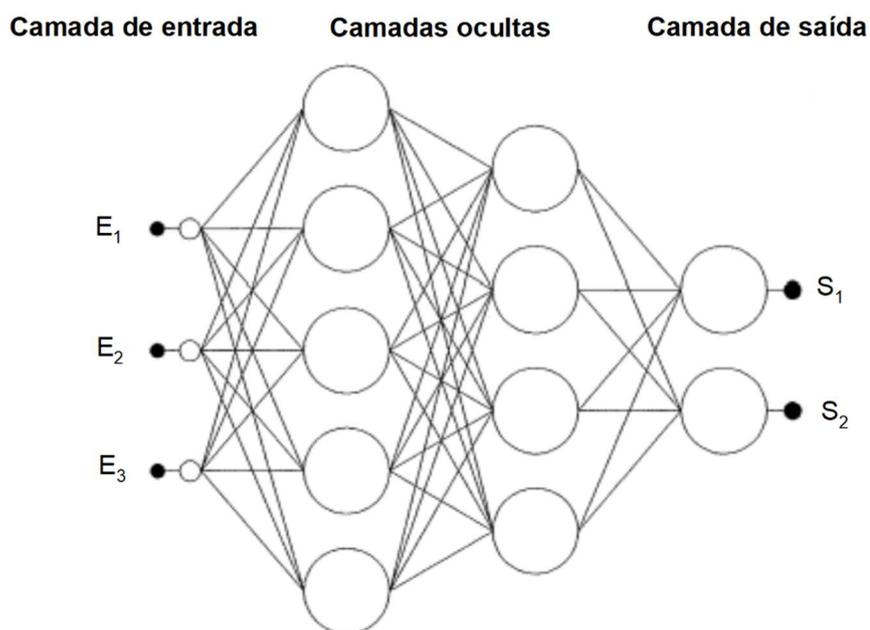


Figura (2.1): Red neuronal Multilayer Perceptron (MLP) con dos capas ocultas.

Fuente: (Gardner & Dorling, 1998).

2.1.4.2 Redes Neuronales Kohonen Self Organizing.

Los *Self Organizing Maps* (SOM) se utilizan como métodos computacionales para la visualización y análisis de datos de gran tamaño.

Los mapas se basan en un aprendizaje competitivo no supervisado cuya fuente de inspiración es la estructura biológica de la corteza cerebral (Kohonen, 1982). La corteza tiene diferentes áreas responsables por diferentes actividades humanas como las motoras, sensoriales, y visuales (Kohonen, 2001).

Las redes de *Kohonen Self Organizing* tienen una topología de dos capas; la primera es la capa de entrada, y la segunda es la capa llamada *Kohonen*. Hay un nodo para cada dimensión en la capa de entrada, donde cada entrada está conectada a todos los nodos en la capa de *Kohonen*, en la que el valor en la última representa la salida y es al menos igual al número de categorías a ser reconocidas (Kohonen & Somervuo, 2002). En la figura (2.2) se muestra la estructura de la red neuronal *Self Organizing Maps*, mostrando las neuronas de entrada y las neuronas de la capa *kohonen*. Las neuronas de entrada están totalmente conectadas con las neuronas de la capa *kohonen* y una neurona ganadora está representada por un punto resaltado.

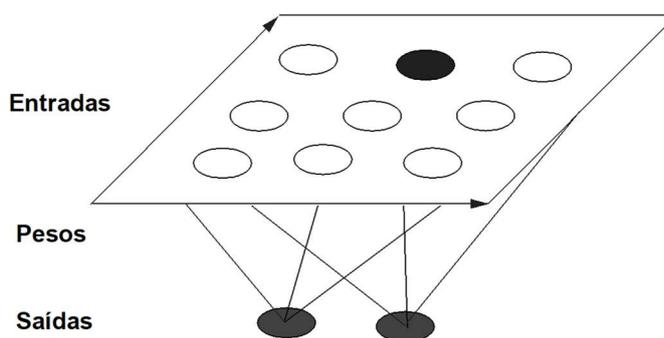


Figura (2.2): Estructura del *Self Organizing Maps*.

Fuente: (Khan, 2018).

2.1.4.3 Redes Hopfield.

Por último, una red neural recurrente se conoce como Red *Hopfield*. Las redes recurrentes poseen la propiedad de flujo de información bidireccional, es decir, hacia adelante y hacia atrás. Los nodos en tales redes están totalmente conectados entre sí y pueden funcionar tanto como entrada y salida. La inestabilidad de los estados se repite hasta que se alcanza un estado estable, lo que garantiza la convergencia de la dinámica (Hopfield, 1982). En general, las redes *Hopfield* se utilizan en problemas de optimización (HOPFIELD, TANK, 1985). En la figura (2.3) se muestra un esquema de la red *Hopfield* con tres puntos. En ella, x_i representa la entrada, y_i representa la salida y w_{ij} equivale a los pesos conectados a las conexiones.

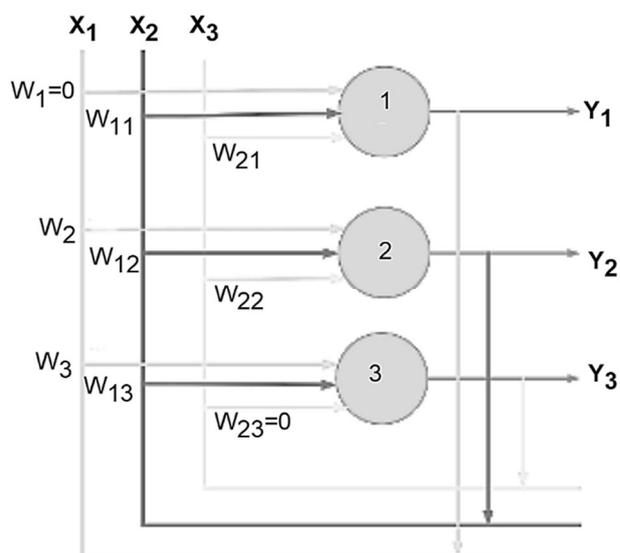


Figura (2.3): Red neural artificial Hopfield.

Fuente: (Khan, 2018).

Capítulo III

III Método

3.1 Tipo de investigación

El diseño óptimo del sistema de energía distribuida en la red inteligente se podría obtener a través de la selección y dimensionamiento optimizado de los recursos de energía distribuida. En ese sentido, se presenta la metodología para obtener los recursos energéticos del productor - consumidor residencial optimizados con la finalidad de reducir los costos de su consumo de energía.

Por tratarse de un problema de optimización, el modelo de solución de problemas complejos con métodos matemáticos ha sido utilizado en esta investigación, y su solución computacional mediante un código apropiado. Es decir, un modelo cuantitativo, con abordaje numérico usualmente computacional, buscando así superar la incertidumbre en la trayectoria de evolución del problema bajo análisis, y sobre las variables del problema.

3.2 Ámbito temporal y espacial

El desarrollo de este estudio comprende básicamente dos períodos diferenciados. El primero se refiere a la identificación, colección y tratamiento de las variables que comprendió el periodo de un año (2017); ello es, principalmente la variable de consumo de energía de la unidad de consumo, así como la identificación de la irradiación solar y temperatura para poder obtener el potencial de energía PV para el punto de estudio.

Debido a que el consumo de energía está directamente ligado a las condiciones estacionales, así como la energía PV, se ha optado por elegir un conjunto de residencias multifamiliares con ubicación geográfica de latitud: -11.881 y Longitud: -77.03 en Lima Metropolitana, para el presente estudio. El segundo periodo comprende el análisis computacional.

3.3 Variables

Para poder resolver el problema de optimización, se presenta un modelo matemático y se describe involucrando 4 variables principales (de entrada, o independientes), así como una variable de salida o dependiente. Seguidamente se presenta la función objetivo y sus debidas restricciones. Todas las variables son definidas en un intervalo de una hora y se determinan como un instante (t).

Las variables consideradas de entrada se refieren al conjunto de datos o registros organizados de la forma a permitir el desarrollo del modelado del productor – consumidor. Entre ellas se tiene a continuación:

$P_{dem,t}$ - Potencia consumida por el consumidor en el instante (t) [kW];

$P_{pv,t}$ - Potencia generada por el sistema PV en el instante (t) [kW];

$M_{pc,t}$ - Precio de compra de la energía de la red en el instante (t) [S/. / kWh];

$M_{pv,t}$ - Precio de la energía fotovoltaica en el instante t [S/. / kWh].

La potencia consumida se obtiene a partir de las mediciones realizadas para un periodo de 4 meses, e por medio del modelo de previsión se obtiene de los 8 meses consecuentes. Los valores estimados de la energía PV se obtienen por medio de la variable obtenida de irradiación solar.

El precio de compra de energía de la red pública se obtiene directamente de la de los datos públicos de precios de la concesionaria para el lugar evaluado. Finalmente, el precio de la energía PV se basa en el cálculo del costo nivelado de energía (LCOE), así mismo, se evalúa el modelado del retorno de la inversión. La variable dependiente esta dado por la minimización del costo del productor – consumidor.

Con base en el modelo de generación distribuida adoptado por el Perú, la energía inyectada en la red no genera ingresos o transacciones bidireccionales de acuerdo con la norma actual al 2018 (D. L. No. 1221, 2015). Sin embargo, a partir del 2019 entrará en vigencia la nueva normativa que consiste en efectuar transacciones económicas entre el productor-consumidor y la concesionaria de energía eléctrica local por medio de la modalidad de generación distribuida NEB (*Net Energy Billing*) (Francisco Ismodes Mezzano, 2018). Ello motiva a realizar el modelado de la generación distribuida considerando esa reciente modalidad adoptada.

Para ello, es necesario definir otras variables que son necesarias para realizar el modelado computacional a fin de simular el comportamiento del productor-consumidor y la red inteligente a partir de las variables principales debido a la no linealidad del modelo, con fines para realizar el modelado con el método matemático de optimización y se presentan a continuación:

$P_{iny, t}$ - es la potencia PV en tránsito hacia la concesionaria (t) en kW;

$P_{rede, t}$ - es el estado y valor de la potencia demandada (concesionaria) o inyectada a la red (fotovoltaica) en el instante (t) en kW.

3.4 Población y muestra

Para el análisis del productor-consumidor, primeramente, se deben obtener los registros de consumo de energía, así como la estimación de la producción de energía fotovoltaica, considerando las limitaciones definidas. Seguidamente se debe obtener los precios de compra de la energía de la concesionaria, así como el cálculo de los precios para la energía fotovoltaica, por intermedio del costo nivelado de energía (LCOE).

La muestra corresponde al periodo de un año con la finalidad de captar los efectos estacionales, según definido en el ámbito temporal y espacial del presente

trabajo. Así, el precio y consumo de energía por parte de la unidad consumidora, y la estimación del potencial y precio de energía PV, fueron obtenidos con una frecuencia de una hora. Es decir, la muestra presenta 24 valores para un día, y comprende un total de 8760 valores para todo el periodo evaluado (1 año), para cada una de las variables de entrada.

3.5 Instrumentos

Los recursos que se utilizó en el presente trabajo corresponden a básicamente a dos etapas. La primera se refiere a los instrumentos de recolección de datos, precisamente de las cuatro variables principales. La primera etapa se subdivide en dos partes y corresponde: (i) la recolección de datos con instrumento de medición; (ii) la estimación de los datos restantes a partir de las mediciones.

El registro de datos se realizó con el medidor *EnergyLOG Plus*, que se usa para monitorización e indicando la calidad del consumo de energía eléctrica para aplicaciones residenciales y comerciales. Este dispositivo almacena los valores medidos de la red con lecturas cada 10 s y promedios de los valores obtenidos cada 1 hora, según lo configurado para este trabajo. Una medición de RMS real puede medir con precisión tanto las ondas puras como las ondas no sinusoidales más complejas.

A partir de las mediciones con el medidor *EnergyLOG Plus*, se obtuvo los valores faltantes para completar el periodo de un año, utilizando modelos de previsión. El método que se utilizó corresponde a las redes neurales artificiales utilizando un computador personal con recursos como de software libre, específicamente el “R Core Team” (2018). Ese recurso modela eficientemente los modelos de previsión en base a las redes neurales artificiales.

Los instrumentos que se utilizaron para la segunda etapa del trabajo corresponden al análisis de optimización mediante un computador personal. El recurso utilizado corresponde al paquete *NlcOptim* de R *team Core (2018)*, que resuelve problemas de optimización no lineal con restricciones de desigualdad lineal y no lineal. Seguidamente, en la sección de procedimientos se presenta a detalle cómo se realizó el análisis del trabajo.

3.6 Procedimientos

3.6.1 Función Objetivo.

Para realizar la optimización del productor consumidor, se tiene que definir la función objetivo, que consiste en optimizar la potencia instalada de energía PV y minimizar el costo de la energía consumida por la unidad evaluada. Esta función objetivo, siendo aquí expresada en la ecuación (3.1) (Williams, 2013).

$$\min F = \min\left(\sum_0^t M_{pc,t} * P_{rede,t} - \sum_0^t M_{pv,t} * (-P_{rede,t}) - \sum_0^t M_{pc,t} * (P_{iny,t})\right) \quad (3.1)$$

La ecuación (4.1) está sujeta a (4.2 y 4.3);

$$P_{rede,t} \geq (P_{pv,t}) \quad (3.2)$$

Donde la restricción (3.2) garantiza que la energía suministrada a la red sea sólo la producida por la energía fotovoltaica. La señal positiva en $P_{rede, t}$

indica la compra de energía y la señal negativa indica la venta de energía fotovoltaica, ambas por el consumidor residencial.

$$P_{dem,t} + P_{iny,t} = P_{pv,t} + P_{rede,t} \quad (3.3)$$

La ecuación (3.3) representa el equilibrio entre la generación de energía fotovoltaica, la energía suministrada por la concesionaria y la demanda energética de la unidad de consumo. El problema de optimización será obtenido con el paquete *NlcOptim* de *R team Core*, que resuelve problemas de optimización no lineal con restricciones de desigualdad lineal y no lineal de la igualdad y, implementando un método secuencial de programación cuadrática (SQP) (Xianyan Chen, 2017).

Sin embargo, las variables principales serán obtenidas separadamente y se utilizan como entradas del modelo, entre ellas, la potencia consumida ($P_{dem,t}$), potencia generada por los paneles fotovoltaicos ($P_{pv,t}$), precio de la energía fotovoltaica ($M_{pv,t}$). El precio de compra de la energía ($M_{pc,t}$) se encuentra disponibles por la concesionaria de energía.

3.6.2 Potencia consumida ($P_{dem, t}$), potencia generada PV ($P_{pv, t}$).

Para determinar la demanda de energía de una determinada unidad consumidora es necesario generar históricos en intervalos de tiempo regulares. Modelar la influencia del productor-consumidor requiere el uso de modelos de previsión para anticipar la demanda y producción de la energía PV. La elección del método de previsión más apropiado depende de diferentes factores; como la

complejidad, la naturaleza y el objetivo del sistema instalado, o la precisión y adaptabilidad de la estimación (Debnath & Mourshed, 2018).

Los modelos de red neuronal artificial permiten estipular relaciones no lineales complejas entre la variable de respuesta y las previsiones (Hyndman & Athanasopoulos, 2014). En este trabajo utilizaremos para la previsión de la demanda energética, el modelo en base a redes neurales artificiales presentado por (Zarate, Fernández, & Motta, 2018), tal y como se presenta en la figura (3.1). Ese modelo propuesto combina las técnicas de *bootstrap* para la suavización previa de las series temporales, seguidamente aplica las redes neurales artificiales para hacer 24 previsiones puntuales a cada una hora, obteniendo previsiones más precisas.

A continuación, se presentan los pasos para el modelado de la previsión que consiste, primero, en realizar una colección de datos de la demanda de energía para poder entrenar el modelo de previsión. De la misma forma se identificarán las variables exógenas que contribuyen en la previsión de la potencia activa PV.

Este estudio utiliza los datos de la demanda de energía eléctrica (kWh) de una unidad consumidora. Estos datos fueron recolectados durante un período de 4 meses, con el objetivo de determinar el perfil de la demanda de energía y, consecuentemente, modelar y validar la previsión utilizando la red neuronal artificial.

El instrumento de medición recolecta las mediciones cada 10 segundos y las medias y totalizaciones de los valores leídos se realizaron cada una hora. Los datos recogidos se almacenaron inicialmente en el dispositivo de medición y posteriormente se transfirieron a un ordenador. Estos datos se utilizan,

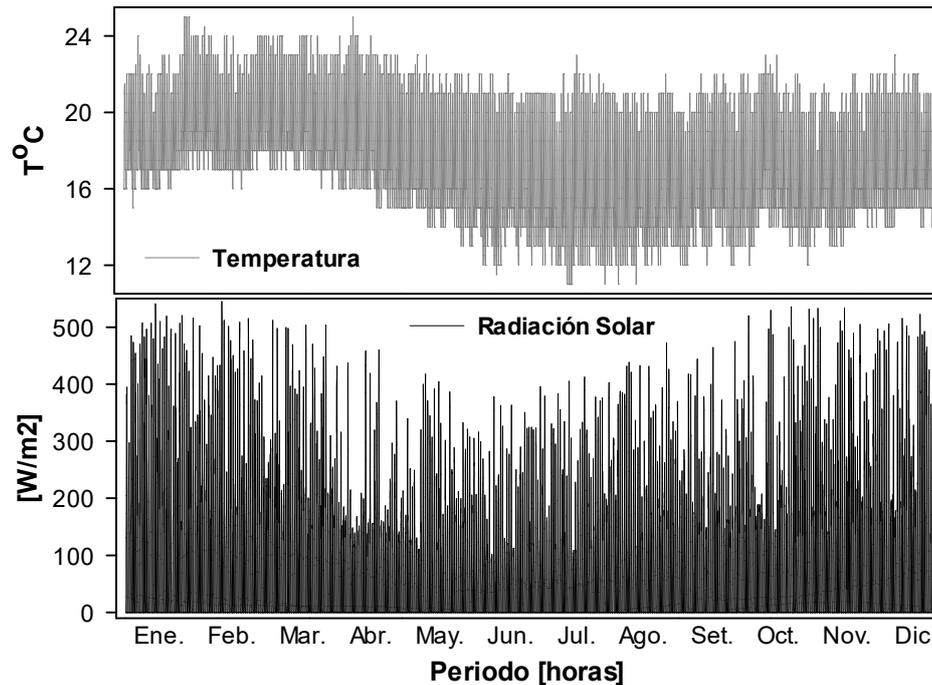


Figura (3.2): Registro de temperatura e irradiación solar para la ubicación de la unidad consumidora evaluada.

Fuente: (NREL, 2018).

3.6.2.1 Arquitectura de red neuronal.

Las redes neurales artificiales se utilizan como redes neurales artificiales basadas en modelos matemáticos del cerebro para el procesamiento de información. Una red neuronal puede ser considerada como un conjunto de neuronas que están organizadas en capas. Las variables conforman la capa de entrada y las salidas (previsiones) forman la capa de salida. También puede haber capas intermedias conformadas por las neuronas ocultas. Los coeficientes asociados a cada capa se llaman “pesos”, los pesos se seleccionan en la configuración de la red neuronal usando un algoritmo de aprendizaje y, al agregar una capa intermedia, la red neuronal se vuelve no lineal (Zarate et al., 2018).

En una red neuronal del tipo *Feed-forward* multicapa, cada capa de nodos recibe entradas de las capas anteriores, mientras que las salidas de los nodos en una capa son entradas a la siguiente. Las entradas para cada nodo se combinan utilizando una interacción lineal ponderada. El resultado es entonces modificado por una función no lineal antes de la salida. Por ejemplo, las entradas en la neurona oculta j en la Figura (3.3) se combinan linealmente como se muestra en la ecuación (3.4) (Hyndman & Athanasopoulos, 2014).

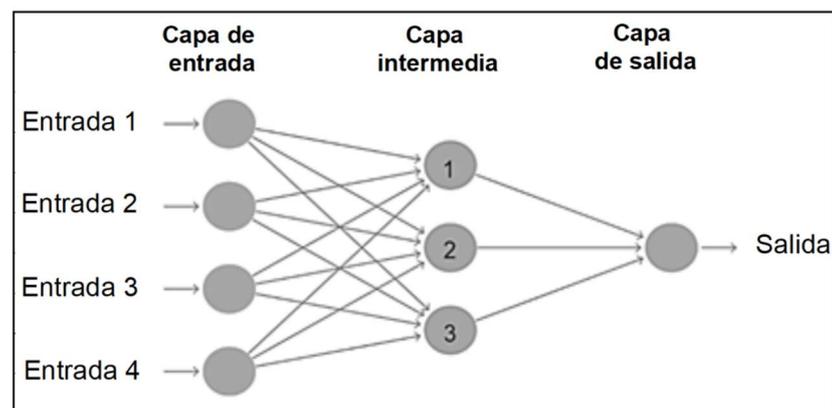


Figura (3.3): Red de *Feed-forward* Multicapa utilizada para la previsión.

Fuente: Adaptado de (Zarate et al., 2018).

$$z_j = b_j + \sum_{i=1}^4 w_{i,j} x_i \quad (4.7)$$

La red neural de *Feed-forward* mostrada en la figura (3.3) contiene cuatro predictores en la capa de entrada y tres neuronas en la capa oculta. Los parámetros b_1 , b_2 , b_3 y $W_{1,1}$, ..., $W_{4,3}$ se encuentran durante la etapa de entrenamiento (Hyndman & Athanasopoulos, 2014). La red generalmente se entrena varias veces usando diferentes puntos de partida aleatorios,

seguidamente, el resultado de la combinación lineal es entonces modificado por una función no lineal antes de la salida de cada capa usando un sigmoide (ecuación 3.5) (Zarate et al., 2018).

$$s(z) = \frac{1}{1+e^{-z}} \quad (3.5)$$

3.6.2.2 Autorregresión de la red neuronal.

Los valores desfasados de la serie temporal se pueden utilizar como entradas para una red neuronal y se denota como un modelo NNAR. Considerando sólo las redes neurales de *feed-forward* con una capa oculta, denotándose de la forma: NNAR (p, P, k) [m], para indicar que existen “p” entradas desfasadas no estacionales, “P” entradas desfasadas estacionales y “k” neuronas en la capa oculta, y [m] representa la frecuencia. En ese sentido, las entradas autorregresivas se presentan de la forma como se indica en la ecuación (4.6) (Zarate et al., 2018).

$$y(t) = (y_t, y_{t-1}, \dots, y_{t-p}, y_{t-m}, y_{t-2m}, y_{t-Pm}) \quad (3.6)$$

La función *nnetar ()* en el *R Core Team* ajusta un modelo NNAR (p, P, k) [m] (Rob Hyndman; et al., 2018). Cuando los valores de p no se especifican, es seleccionado de la siguiente manera: para las series temporales estacionales, los valores propuestos son P = 1 y p se elige a partir del modelo lineal mejor ajustado a los datos desazonalizados, de acuerdo con el criterio de información de Akaike - AIC. Si k no se especifica, se

ajusta a $(p + P + 1) / 2$, aproximándose al valor entero más cercano. La frecuencia diaria [m] es igual a 24, ya que durante al día se tiene 24 valores para ambos casos de previsión, tanto de la demanda energética, como de la potencia activa PV.

3.6.2.3 Estimación del error de previsión y la validación cruzada.

Un error de previsión es la diferencia entre un valor observado y su previsión, que surgen por la comparación entre ambos valores, que normalmente se realiza en la etapa de entrenamiento de la red neural artificial (Hyndman & Athanasopoulos, 2014). En ese sentido, un error de previsión se denota en la ecuación (3.7).

$$e_t = \hat{y}_t - y_t \quad (3.7)$$

Un indicador de error de previsión muy utilizado se denomina error porcentual absoluto medio (MAPE), así como el error cuadrático medio (RMSE), que también es muy utilizado para medir la precisión de las previsiones. Estos se indican en las ecuaciones (3.8) y (3.9), respectivamente (Zarate et al., 2018).

$$MAPE = \left(\frac{\sum_{t=T+1}^{T+h} \left| \frac{e_t}{y_t} \right|}{h} \right) \times 100\% \quad (3.8)$$

$$RMSE = \sqrt{\frac{\sum_{t=T+1}^{T+h} (e_t)^2}{h}} \quad (3.9)$$

El RMSE como el MAPE pueden identificar de una forma objetiva las precisiones de los modelos de previsión. Sin embargo, cuando se trata de modelos autorregresivos es necesario identificar que los modelos no estén sobre ajustados (*overfitting*). Uno de los procedimientos estándar más robustos que complementan la evaluación e identifican el sobre ajuste de los modelos en regresión es la validación cruzada (CV) en K-fold (Bergmeir, Hyndman, & Koo, 2018).

Cuando los métodos de aprendizaje de máquina se utilizan para previsiones puntuales, el CV es apropiado para controlar el sobre ajuste del modelo, identificando los errores correlacionados. Esa ocurrencia puede ser fácilmente identificada, utilizando la prueba de *Ljung-Box*. Los valores próximos a la unidad (1), obtenidos mediante la prueba se *Ljung-Box*, indican que los residuos provenientes de la validación cruzada son altamente insignificantes en términos de correlación, pudiendo validarse los modelos (Bergmeir et al., 2018).

3.6.3 Estimación del precio de energía de la concesionaria (M_{rede} , t).

El organismo supervisor de la inversión en energía - Osinergmin, es la institución quien revisa, aprueba, regula, fija, y modifica las tarifas eléctricas. Ese organismo regulador, por medio de la gerencia de regulación de tarifas – GRT, calcula y propone las tarifas al consejo directivo para su aprobación (Osinergmin, 2018). En consecuencia, las distribuidoras asignadas a cada sector se acondicionan a estos precios establecidos por el ente regulador.

Para el estudio de este trabajo, se hace referencia a los pliegos tarifarios vigentes de la distribuidora Enel Distribución (ex - Edelnor) para el año 2018,

y se muestran en la tabla (1) (Enel, 2018b). Las unidades consumidoras (UCs) residenciales corresponden al grupo B del sistema tarifario, descrito específicamente por el subgrupo y el grupo BT5B (tarifa con simple medición de energía).

El período comprendido entre las 18:00 y las 23:00 horas de cada día de todos los meses del año es considerado como horas punta (HP). Exceptuándose los domingos, feriados nacionales del calendario regular anual y los feriados nacionales extraordinarios programados en días hábiles, teniendo en cuenta también las condiciones específicas de cada opción tarifaria. Las horas fuera de punta (HFP), corresponden al resto de horas del mes no comprendidas en las horas de punta (HP) (Osinerg, 2001), (Zarate, Fernandez, & Da Motta, 2018).

Tabla (1). Tarifa residencial con simple medición de energía (zona Lima Norte)

TARIFA BT5B:	Cargo Fijo Mensual	Cargo por Energía Activa
	S/. /mes	ctm. S/. /kW.h
Ene	3,04	60,46
Feb	3,06	62,68
Mar	3,07	62,98
Abr	3,07	62,99
May	3,10	60,61
Jun	3,10	60,61
Jul	3,13	60,92
Ago	3,13	60,88
Set	3,13	60,88
Oct	3,14	59,03
Nov	3,23	60,86
Dic	3,23	60,86

Fuente: (Enel, 2018b).

3.6.4 Estimación del costo de la energía PV (Mpv,t).

Para estimar el costo nivelado de energía (LCOE) asociado a los sistemas de generación PV, en este trabajo, se utiliza la metodología propuesta por (Ouyang & Lin, 2014). En ese sentido, el LCOE es la relación entre los costos de inversión, operación y mantenimiento, y la cantidad de energía producida durante la vida útil del sistema.

Los costos de inversión, operación y mantenimiento se calculan en base a los costos de los dispositivos del sistema, así como los impuestos y tasas de transporte. La cantidad de energía producida durante la vida útil del sistema está ligada directamente con la radiación solar y la potencia nominal del sistema (Ouyang & Lin, 2014).

3.6.4.1 Cálculo de la producción de energía.

Para estimar la producción de energía PV, es necesario considerar la vida útil del sistema de energía PV, considerado entre 15 y 25 años (Lesourd, 2001). En este trabajo, se considera una vida útil de 20 años. La cantidad de energía producida anualmente (E_{anual}) se puede calcular a partir de la ecuación (3.10).

$$E_{\text{anual}} = \frac{Q_{\text{solar}} * P_m * K_{\text{uso}}}{I_{\text{ref}}} \quad (3.10)$$

Donde,

E_{anual} es la energía PV producida en un año en [kWh / año];

Q_{solar} es la radiación media diaria (en promedio anual) de 4,48 [kWh/m².dia] (Zarate Pérez et al., 2018);

P_m es la potencia nominal del sistema, en las condiciones STC (condiciones estandarizadas de prueba).

I_{ref} representa la radiación estándar (1 kW/m²).

K_{uso} es el factor de condiciones únicas del lugar evaluado, estimado en 70% (Zarate Pérez et al., 2018), y a su vez basado en dos grupos de factores (Lacchini & Dos Santos, 2013):

(a) La incertidumbre de la radiación solar sujeta a las condiciones meteorológicas, la caída de tensión en los conectores del módulo y del inversor. (b) La eficiencia de los convertidores y transformadores en el proceso de conversión DC a AC.

Una vez obteniendo la producción anual de energía (E_{anual}), la energía total (E_{total}) se calcula durante la vida útil del sistema a partir de la ecuación (3.11).

$$E_{total} = \sum_1^N E_{anual} * (1 - D_{anual,i})^{(n-1)} \quad (3.11)$$

Donde,

D_{anual} es el coeficiente de decaimiento anual del 0,5% en el rendimiento de pérdida de eficiencia de los módulos solares debido al envejecimiento (Lacchini, 2017).

3.6.4.2 Cálculo de la inversión de capital.

El cálculo de inversión del capital para el sistema fotovoltaico se realiza a partir de datos de precios unitarios e informaciones recibidas de

empresas locales, ya incluidos los impuestos correspondientes que el importador o vendedor tributa para ofrecer los productos al usuario final.

Tabla (2). Precios unitarios de los dispositivos del sistema de generación PV [S/. kWh].

Descripción	Costo por unidad [S/./kWp], incluye IGV
Módulo	2920,37
Inversor	1231,68
Cable	585,65
Estructura	840,94
Permiso de conexión	342,00
Instalación	593,75
Proyecto (monto fijo)	1106,99
Proyecto (Monto variable [S/./kWp])	429,88

Fuente: Elaboración en base a información de empresas especializadas en el sector.

La tabla (2) indica los costos unitarios de los componentes que intervienen en el proceso de instalación del sistema PV. Esta información fue obtenida directamente por las empresas proveedoras de venta de dispositivos PV. Los costos unitarios del medidor bidireccional es de competencia de la empresa de distribución (Enel, 2018a). El costo total del sistema incluye el valor de la operación, seguro y mantenimiento calculándose como el 1% de la inversión inicial, sobre una base anual para los sistemas mayores a 5kWp (Lacchini & Dos Santos, 2013).

Tabla (2): Precios unitarios de los dispositivos del sistema de generación PV [S/. kWh].

Descripción	Costo por unidad [S/. /kWp], incluye
	IGV
Módulo	2920,37
Inversor	1231,68
Cable	585,65
Estructura	840,94
Permiso de conexión	342,00
Instalación	593,75
Proyecto (monto fijo)	1106,99
Proyecto (Monto variable [S/. /kWp])	429,88

Fuente: Elaboración en base a información de empresas especializadas en el sector.

3.6.4.3 Costo nivelado de energía (LCOE).

Una vez obtenida la energía total generada durante la vida útil del sistema y el costo de inversión de capital, operación y mantenimiento (O & M), se procede a calcular el costo nivelado de energía (LCOE) basándose en la ecuación (3.12).

$$\text{LCOE (R\$/kWh)} = \frac{[C_{\text{inicial}} + \sum_1^N \frac{O \& M}{(1+r)^n}]}{E_{\text{total}}} \quad (3.12)$$

Donde,

C_{inicial} es el capital inicial invertido;

$O \& M$ es el costo anual de operación y mantenimiento del sistema, considerado como el 1% de la inversión inicial (Lacchini & Dos Santos, 2013);

(r) se refiere a la tasa de descuento anual, correspondiente a la inflación del 6%.

3.6.4.4 Retorno de la inversión.

La tasa interna de retorno (TIR) es la tasa que iguala el valor presente de las entradas de caja con el valor presente de las salidas. Es decir, la tasa de descuento que hace que el valor presente neto (VPN) de un proyecto sea igual a cero. El cálculo del VPN es un indicador estándar para considerar si un proyecto de inversión debe ser realizado o no. La tasa de interés $\text{\textcircled{R}}$ se utiliza para determinar cuál es el valor de los flujos de efectivo futuros en los ingresos actuales. Un proyecto se considera viable siempre que la suma de las entradas de caja menos el valor presente de la suma de las salidas de caja sea mayor o igual que cero (ECREEE, 2006).

Para encontrar la tasa interna de retorno en función del valor presente neto, se utiliza la siguiente ecuación (3.13):

$$P = \frac{R_1}{(1+TIR)} + \frac{R_2}{(1+TIR)^2} + \dots + \frac{R_n}{(1+TIR)^n} = \sum_{t=1}^n \frac{R_t}{(1+TIR)^t} \quad (3.13)$$

Una vez obtenida la tasa de retorno interna (TIR), esta se debe evaluar con el costo de oportunidad. Si la tasa de interés (i) de mercado es inferior a la TIR, entonces se puede deducir que el proyecto es viable desde el punto de vista financiero.

Si $TIR > i$, se realiza la inversión;

Si $TIR < i$, no se realiza la inversión;

Si $TIR = i$, indiferente realizar o no la inversión.

La tasa interna de retorno modificada (TIRM) es también un método de análisis de proyectos de inversión que consiste en traer los flujos de caja negativos a valor presente y llevar los flujos de caja positivos para valor futuro, resultando en un nuevo flujo de caja convencional y eliminando así algunos de los problemas de la TIR, cuando es estimada en su manera tradicional y se expresa en la ecuación (3.14).

$$TIRM = \left[\frac{\text{Valor Futuro das Entradas}}{\text{Valor Presente das Saídas}} \right]^{(1/n)} \quad (3.14)$$

Aceptar TIR obtenida \geq Tasa mínima de atractividad.

El valor presente neto (VPN), es la fórmula matemático-financiera capaz de determinar el valor presente de pagos futuros descontados a una tasa de interés apropiada, menos el costo de la inversión inicial. Y para obtener el beneficio económico neto, aún es necesario descontar el costo de inversión del proyecto. El VPN se define por la ecuación (3.15).

$$VPN = \sum \frac{R_t}{(1+i)^n} - P \quad (3.15)$$

Para el análisis de inversiones, un concepto importante es el período de recuperación del capital denominado como *Payback*. Ese concepto se define como el tiempo necesario para recuperar la inversión original. Cuanto

menor sea el plazo de recuperación del capital, menor el riesgo del emprendimiento, así él debe ser tomado como medida de riesgo en la elección entre diferentes proyectos de inversión (Wambach, 2000).

3.7 Análisis de datos

Una vez definido el procedimiento metodológico que se aplica en este estudio se procede a realizar el análisis de datos para poder cumplir el objetivo propuesto. El análisis de los datos corresponde al modelado del productor - consumidor de energía que en base a las variables de entrada que comprende la demanda de energía de la unidad consumidora, el estimado de la producción de energía PV, costo de la energía de la red de la concesionaria y el precio estimado de la energía PV.

El resultado del análisis corresponde a la optimización de los costos del consumidor, que, en base a las variables mencionadas, se puede encontrar el valor óptimo de la potencia del sistema PV con la finalidad de reducir los costos por energía de la unidad consumidora, teniendo en cuentas dos casos de estudio que se describe a seguir.

Para el primer caso de análisis corresponde al consumidor de energía residencial que adopta el consumo de energía de la modalidad tarifaria monomía sin generación de energía PV. El segundo caso corresponde al consumidor - productor que adopta la producción de energía en base a la energía PV, que serán comparados para determinar si la adopción de generación eléctrica con esa nueva fuente energética es favorable.

Capítulo IV

IV Resultados

Partiendo del capítulo anterior que trata sobre la metodología para modelar productor-consumidor residencial en la red eléctrica, con el propósito de obtener una solución más favorable económicamente obteniendo el equilibrio eléctrico. Entre las variables de entrada que se debe tener para modelar es la demanda de energía, el precio de compra de la energía de la red pública, la potencia activa fotovoltaica, y el precio estimado de la energía fotovoltaica.

En este capítulo, se presenta los resultados del estudio y está organizado de la siguiente manera: (i) Previsión de la demanda de energía, en base a las mediciones de carga de la unidad consumidora, para completar la obtención de datos para el periodo de un año. (ii) Estimación del costo nivelado de energía fotovoltaica, en base a irradiación solar, producción anual de energía y durante la vida útil del sistema, cálculo del costo inicial del capital. (iii) Finalmente, se realizará el análisis de optimización del costo de energía eléctrica del productor-consumidor de la unidad consumidora evaluada.

4.1 Previsión de la demanda de energía

Las previsiones que se muestran para obtener los valores tanto de la demanda de energía se basan en la arquitectura de la red neural *feed-forward* presentada en la figura (4.1). Las entradas $E_{(t)}$, $E_{(t-1)}$, $E_{(t-2)}$, ..., $E_{(tn)}$, $E_{(tp)}$, E_{TM} , $E_{(t-2m)}$, $E_{(t-Pm)}$ son datos consecutivos de los valores medidos de la demanda de energía del edificio para obtener valores de la carga de energía, y entradas de la temperatura e irradiación solar para la previsión de la carga activa PV utilizadas como vectores de regresión externa; y $E_{(t)+1}$ es la capa de salida o la estimación de la previsión. H_1 , H_2 , H_3 , ..., H_n son las neuronas en la capa oculta.

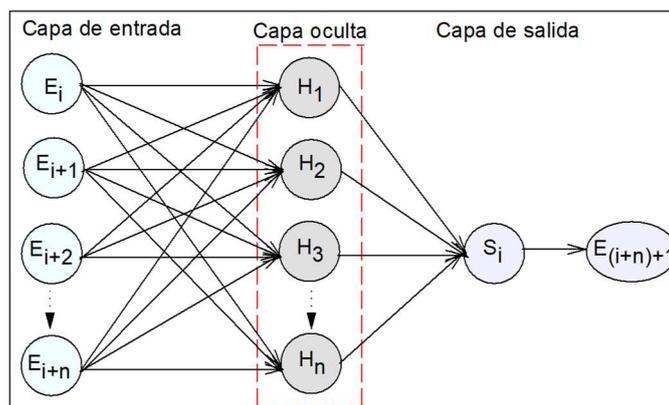


Figura (4.1): Arquitectura de la red neuronal Feed-Forward utilizada en este trabajo.

Fuente: Adaptado de (Zarate et al., 2018).

Finalmente, para realizar las validaciones de las previsiones y verificación del desempeño del modelo se realizó el procedimiento de validación cruzada de K-fold, con los indicadores MAPE y RMSE seguido de la prueba de Ljung-Box, que valida el modelo evaluando si los errores de las previsiones no están correlacionados.

4.1.1 Previsión para la demanda de energía (Pcarga,t).

En la figura (4.2) se muestra las previsiones de la demanda de energía. Los meses de enero a abril representan los valores medidos, y para los meses de mayo a diciembre muestra los valores previstos. El modelo de previsión con el mejor rendimiento para la previsión de la demanda de energía es el $nnar(6,1,5)$ [12], que consta de siete entradas de desfasadas no estacionales, una (1) de entrada desfasada estacional y 4 neuronas en la capa oculta. Con una media de 20 redes, cada una de las cuales es una red 8-5-1 con 45 opciones de pesos - unidades lineales de salida.

La Tabla (3) muestra los resultados medios de la validación cruzada de *K-fold* y de la prueba de Ljung-Box para la demanda de la unidad consumidora.

Para realizar la validación cruzada se utilizó los primeros 7 días para la primera medición, continuo sucesivamente hasta el día 90 de los valores obtenidos a través de la medición de la demanda de energía.

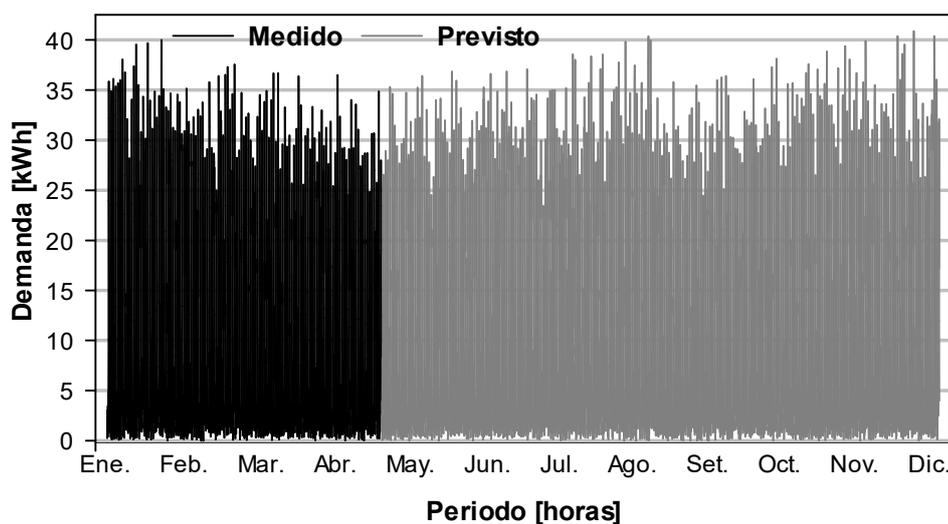


Figura (4.2): Demanda de energía medida y prevista para un año.

Fuente: Elaboración en base a los datos del trabajo.

Tabla (3). Resultados de la validación cruzada de K-fold y prueba de Ljung-Box para los valores obtenidos por medio de las previsiones de la demanda energética.

Indicador	Ajuste	Validación
RMSE	0,039	0,053
MAPE	1,62	2,25
Prueba de Ljung-Box		0,95

Se realizó la prueba de *Ljung-Box* para descartar que no conduzcan a errores fuertemente correlacionados. El resultado de la media según la validación cruzada presentó un valor cercano a la unidad, por tanto, los

resultados verificaron que los errores de predicción no están correlacionados y validan los resultados obtenidos.

4.2 Estimación del costo de energía PV ($M_{solar, t}$)

4.2.1 Producción anual de energía (E_{anual}).

Para los cálculos de la producción de energía anual se eligió el ángulo de inclinación del panel fotovoltaico de $12^\circ N$ (ángulo de mayor promedio anual), con un promedio anual de $5,22 \text{ kWh/m}^2/\text{día}$, con una potencia nominal del panel PV de (P_m) de 320 [Wp] , eficiencia del $16,97\%$ (η_{panel}), y con área útil ($1,90\text{m} \times 0,94\text{m}$) de $1,79 \text{ m}^2$ (CanadianSolar, 2018). Para tener una apreciación de la producción anual (ecuación 3.10) basada en diferentes potencias de instalación, la figura (4.3) presenta basada en la combinación de diferentes paneles de $0,32 \text{ [kWp]}$.

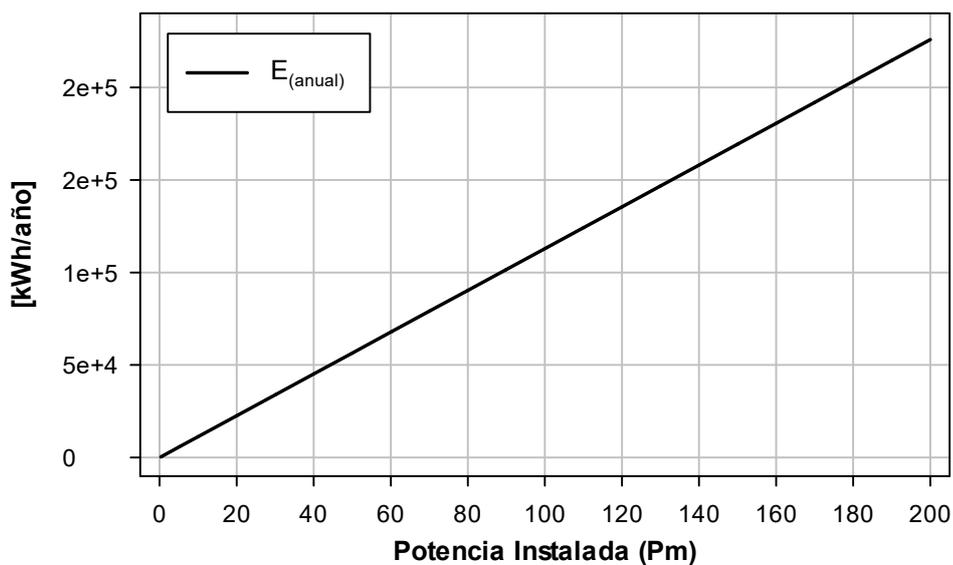


Figura (4.3): Producción anual de energía PV para diferentes potencias instaladas.

4.2.2 Producción de energía durante la vida útil del sistema PV (E_{total}).

Una vez obtenidos los valores de la producción de energía anual, se pasa a modelar la producción de energía total durante la vida útil del sistema PV, con apoyo en la ecuación (3.11), considerando el coeficiente de decaimiento anual (D_{anual}) de 0,5%, según se define en el capítulo metodológico (LACCHINI, 2017). En ese sentido se considera el decaimiento anual de producción de energía PV debido al envejecimiento del sistema de PV para un período de 20 años, y se presenta en la figura (4.4).

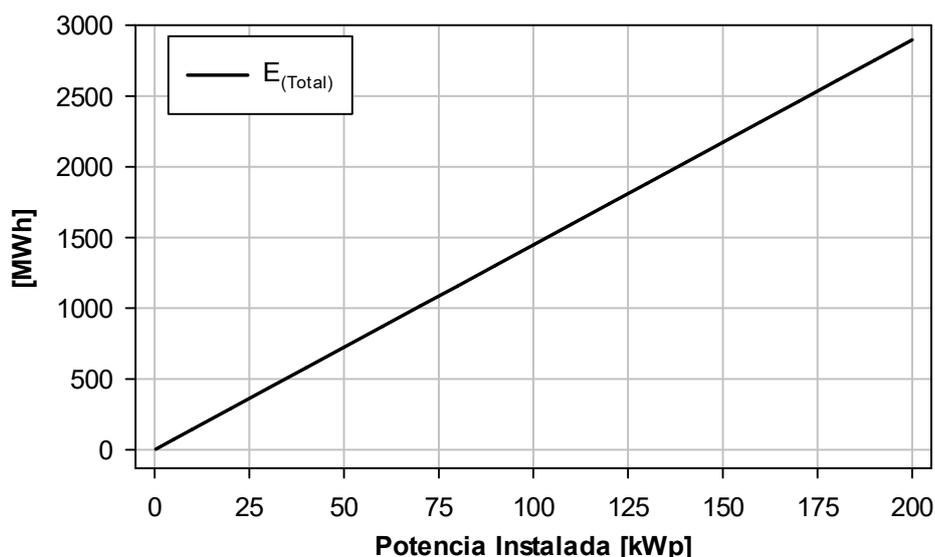


Figura (4.4): Producción de energía durante la vida útil del sistema para diferentes potencias.

4.2.3 Cálculo de la inversión del capital (C_{inicial}).

A partir de los costos unitarios obtenidos directamente de la empresa proveedora mostrados en la tabla (2), se pueden calcular tanto los costos iniciales como los de operación y mantenimiento. El precio unitario

corresponde a todos los componentes que caracterizan el sistema PV, entre ellos: el módulo, el inversor, el cable, la estructura, el permiso de conexión, la instalación y el proyecto (valor fijo y variable).

La figura (4.5) expresa los costos iniciales para diferentes potencias instaladas de sistemas PV considerando los precios unitarios de la tabla (2) y atendiendo sistemas de hasta 200 [kWp]. Para calcular el costo total del sistema PV, el costo por operación, seguro y mantenimiento (O&M) corresponden al 1% / año de la inversión inicial presentada en la figura (4.5) para cada una de las potencias de instalación presentadas.

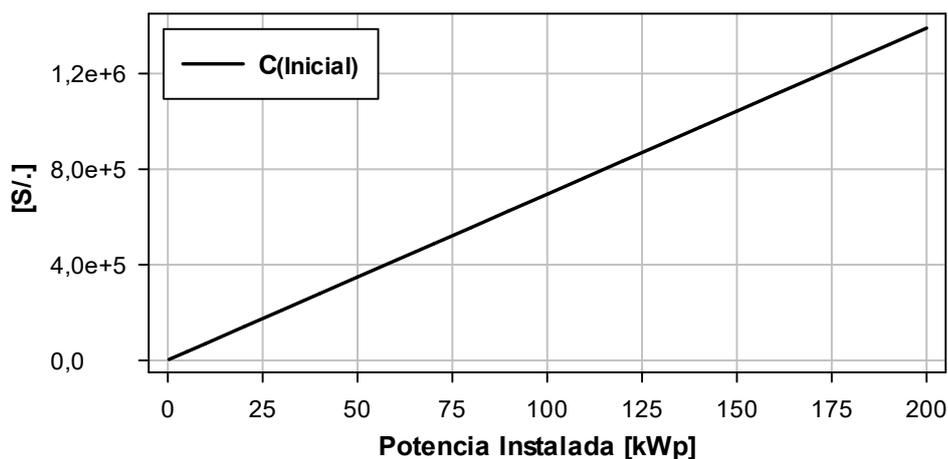


Figura (4.5): Costo inicial (C_{inicial}) para diferentes potencias de instalación (P_m).

4.2.4 Costo nivelado de energía (LCOE).

Finalmente, para calcular el costo nivelado de energía (LCOE) es necesario considerar la tasa de descuento anual que influye en los costos de O&M, correspondiente a la inflación del 6%. En base a la ecuación (3.12) se

calcula el costo nivelado de energía (LCOE) basado en los valores obtenidos de la energía total acumulada durante la vida útil del emprendimiento (E_{total}), el costo de inversión de capital ($C_{inicial}$), operación y mantenimiento (O&M), considerando cero el valor residual al final de la vida útil del emprendimiento. En la figura (4.6), se muestra el LCOE para diferentes potencias instaladas (P_m) de sistemas PV.

El costo nivelado de energía para las diferentes potencias de instalación de sistemas fotovoltaicos hasta 200 [kWp], que se muestran en la figura (4.6), varía entre 55.40 a 53.8 Cent. S/. / kWh, estos valores equivalen al precio estimado de la energía PV y se utilizan también para modelar el retorno de la inversión privada.

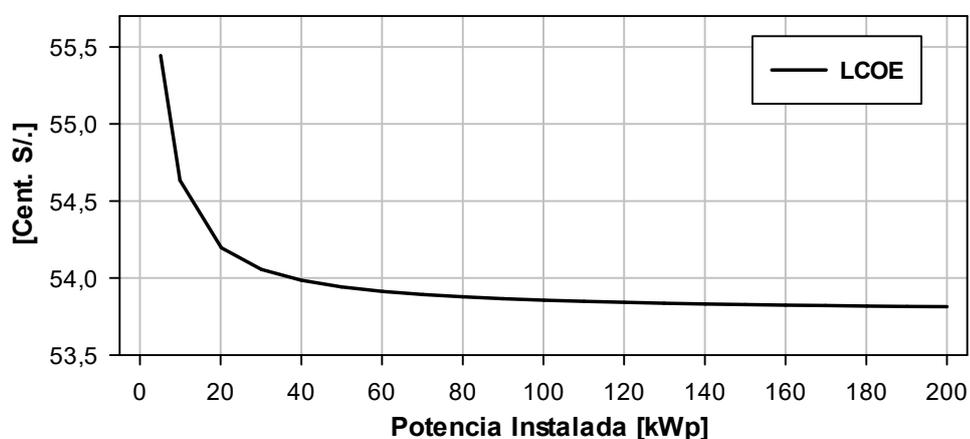


Figura (4.6): Costo nivelado de energía (LCOE) con diferentes potencias instaladas.

4.2.5 Retorno de la inversión.

Para determinar el retorno de la inversión de la producción de energía PV, se considera como referencia la tarifa tradicional de la energía de la red pública, con su respectivo incremento anual sobre el precio actual a cada uno

año. Generalmente se utiliza un incremento anual del costo de la energía eléctrica de la red pública residencial del 6%.

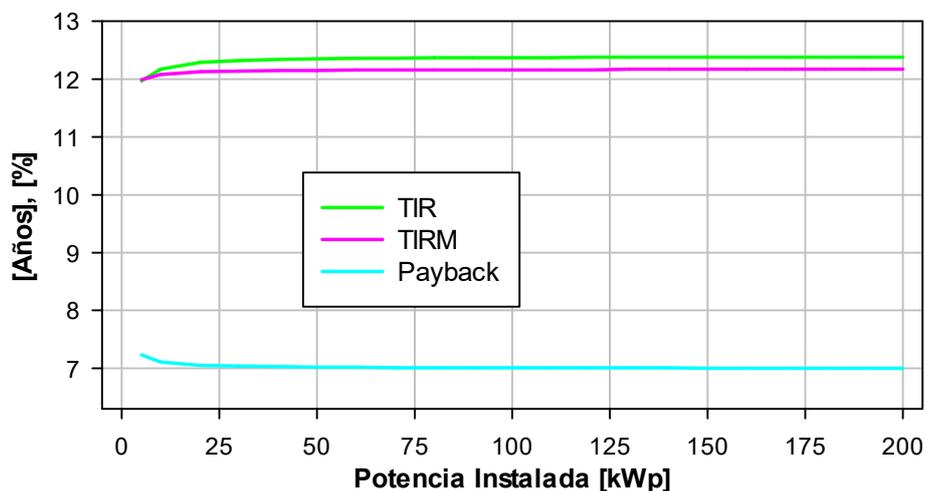


Figura (4.7): La TIR y TIRM para diferentes potencias instaladas (P_m) con un incremento de precio de la energía eléctrica del 6% al año y con una tasa de interés (i) del 12%.

Con la finalidad de encontrar la tasa interna de retorno (TIR) en función del valor presente líquido se sigue la ecuación (3.13). Teniendo en cuenta que, si la tasa de interés (i) del mercado es inferior a la TIR, entonces se puede decir que el proyecto es viable desde el punto de vista financiero. En ese sentido, la TIR tendrá que ser a la TIRM (ecuación 3.14). En la figura (4.7), se presentan los indicadores TIR y TIRM para las diferentes potencias instaladas [kWp] del sistema de generación PV considerando un incremento del precio de 6% a cada año en el precio de la energía eléctrica residencial y una tasa de intereses (i) del 12%.

En la figura (4.7), la TIR tiene un porcentaje mayor que la tasa de interés y la TIRM para todas las potencias instaladas excepto para la potencia

de 0,3kWp. El tiempo de retorno de la inversión es de 7,35 años para la potencia de 5kW, ya para las potencias de 200kWp es aproximadamente 7 años. Considerando un aumento del precio del 6% para la energía de la concesionaria, la TIR asigna un valor del 12,17% hasta el 12,38%. Para los mismos valores, la TIRM logra un valor de 12,08 hasta el 12,17%, considerándose viables desde el punto de vista financiero a partir de 2 kWp de potencia instalada.

4.3 Optimización de los costos de energía del productor - consumidor

Una vez definidas las variables que permiten modelar un consumidor de energía de la red pública que es al mismo tiempo productor de energía PV, es necesario establecer algunos escenarios para el análisis mencionado. En primer lugar, se hace referencia a las variables principales de entrada determinadas en los pasos anteriores, entre las cuales se tiene las siguientes.

Potencia consumida por el consumidor en el instante (t) [kW], En la figura (5.13) se presentan tanto la potencia medida como la potencia obtenida por intermedio de la previsión utilizando los modelos de redes neurales artificiales.

Potencia generada por los paneles fotovoltaicos en el instante (t) [kW], de la misma forma que fue definida la potencia demandada de la unidad consumidora, la potencia activa PV fue obtenida también en base a los modelos de redes neurales artificiales utilizando las variables exógenas de irradiación solar y temperatura.

$M_{comp, t}$ - Precio de compra de la energía en el instante (t) [Cent. (S/. / kWh)], fue determinada por los puestos tarifarios presentados.

$M_{solar, t}$ - Precio de la energía PV en el instante t (Cent. S/.), que incluye tasa de interés (i) mínima del 12%, como se muestra en la figura (4.7).

4.3.1 Estudio de caso.

El estudio de caso se refiere al modelado del productor-consumidor para un horizonte temporal de un año. En el análisis del estudio de caso, se asumió que el productor-consumidor puede, en todas las horas, comprar energía de la concesionaria o vender el exceso de energía para el cumplimiento de la demanda de carga no disponiendo de un límite presupuestario diario y mensual a cumplir. Se considera también la demanda de energía obtenida tanto con base de las mediciones realizadas, como de los datos obtenidos a través de la previsión, presentada en la figura (4.2).

Caso 1- Tarifa residencial de simple medición de energía (1E) sin generación de energía PV

En este caso, se considera el consumidor residencial que no genera energía PV y es, solamente, consumidor de la red eléctrica de la red pública, adoptando la tarifa residencial con simple medición de energía 1E, que fue presentada en la tabla (4).

Caso 2 - Tarifa residencial de simple medición de energía (1E) con generación de energía PV

En este marco, se considera que el consumidor residencial que es simultáneamente productor de energía PV e inyecta el excedente de la energía en la red eléctrica de la concesionaria adoptando la tarifa residencial de simple medición de energía 1E, expuesta en la tabla (4).

4.3.1.1 Resultados para el caso (1).

El resultado para el consumidor residencial que adopta la tarifa de simple de medición de energía (1E), con un consumo anual estimado de

72073 [kWh], obtiene un costo de S/.44082 distribuido proporcionalmente como un consumo mensual para un año completo, y se muestra en la figura (4.8). En este caso, el consumidor de energía se comporta como un componente pasivo de la red de energía eléctrica, no teniendo una interacción con los otros componentes.

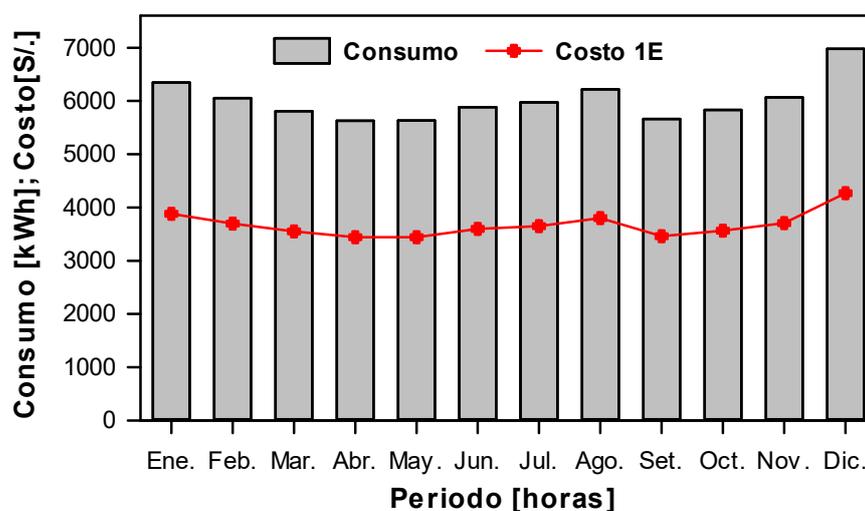


Figura (4.8): Costos horarios para un período optando la tarifa de simple medición de energía sin generación de energía PV.

Cuando el consumidor residencial adopta esta modalidad de simple medición de energía, el costo de su consumo es directamente proporcional a su gasto, caso que podría resultar de una forma diferente con la tarifa de doble medición de energía (2E) – no tratado en este estudio. Los consumos más altos que se presenta corresponden para los meses de enero y diciembre. Ello podría equilibrarse con la generación de energía PV, ya que su mayor producción corresponde también para esos periodos.

4.3.1.2 Resultados para el caso (2).

Los consumidores que adoptan la generación de energía PV tiene una reducción del costo en un 16.74%, esto es para el consumidor que opta por la tarifa de simple medición de energía - 1E y la generación de energía PV. La figura (4.9) muestra el costo de la energía de la red, que es complementada por el costo de la energía PV utilizada por el consumidor; y el costo o ingreso de la energía PV inyectada en la red pública, que reduciría los costos totales de energía.

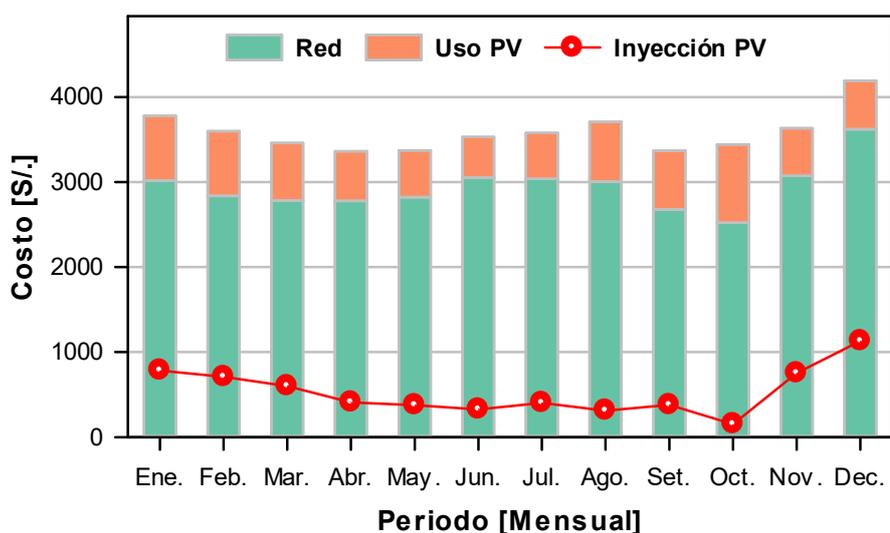


Figura (4.9): Costos mensuales para la tarifa de medición simple cuando se opta por la producción de energía PV.

Para las condiciones específicas del consumidor residencial que opta por la producción de energía PV, considerando el modelo de compensación del NEB (*Net Energy Billing*), el valor optimizado de la potencia de instalación del sistema PV resulta ser de 43.92kWp. Ese valor encontrado en

base al modelo de optimización hace que costo final anual del consumo de energía sea menor desde el punto de vista económico.

En el análisis de los costos y consumo semanal presentado en la figura (4.10), se observa que existe un incremento considerable a causa de la demanda estacional diaria, especialmente en horas de punta. Optando por la nueva modalidad que se adoptará en el Perú, que se consiste en realizar transacciones en dos direcciones, tanto por el consumidor – productor de energía, así como por parte de la concesionaria, tiene como resultado la reducción de los costos en más de 16%, cuando se opta por la producción de energía PV.

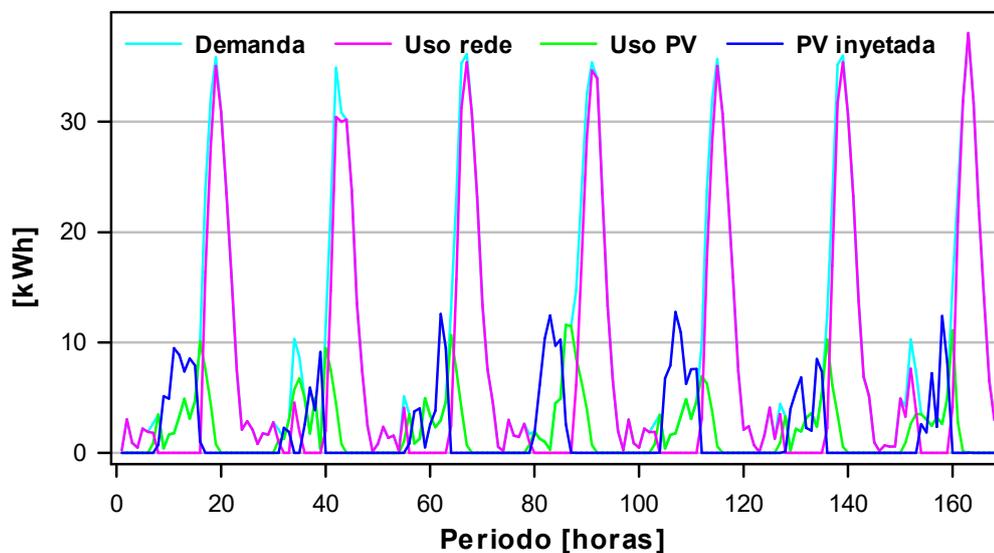


Figura (4.10): Equilibrio energético de la demanda y producción de energía PV semanal evaluados con periodos de una hora.

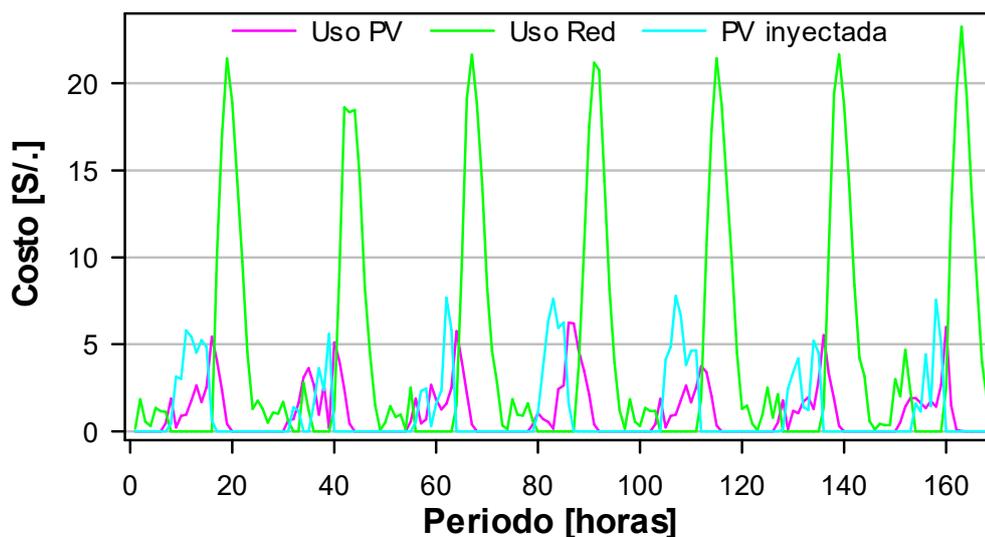


Figura (4.11): Costos de la energía optando la tarifa 1E, y de la energía PV usada e inyectada con periodos de una hora.

En la figura (4.10) se muestra la optimización de los recursos energéticos en base a la red de la concesionaria y también por medio de la producción de energía PV. Se aprecia una alta demanda en los horarios de punta (18:00 – 23:00), esa demanda es básicamente cubierta por la red de energía eléctrica debido a que la mayor producción por parte del sistema PV se registra en otro periodo – mediodía, por lo tanto, la cantidad de energía inyectada en el horario es alta, y por tratarse de una modalidad de simple medición de energía, no impacta los precios de una forma negativa al momento de realizar transacciones desde el lado del consumidor.

Capítulo V

V Discusión de Resultados

La función de optimización que tiene como objetivo encontrar una potencia de instalación ideal del sistema PV en función de la minimización de los costos, puede encontrar satisfactoriamente esa potencia, ya que potencias muy pequeñas comparando con la demanda de energía, no lograrían algún impacto considerable en la reducción de los costos. De la misma forma, las potencias de instalación sobredimensionadas incrementarían el costo inicial del sistema, influyendo directamente en la viabilidad del proyecto y sin incrementar, posiblemente, reducciones significativas al costo del consumidor.

Los resultados obtenidos del modelado muestran que para los consumidores que optan por la tarifa tradicional 1E y la producción de energía fotovoltaica, obtienen una reducción aproximadamente del 16,74 % en los costos anuales de consumo de energía eléctrica. Ello está en concordancia con el análisis de sensibilidad de costos de Salpakari & Lund (2016), que obtiene también una reducción entre 13 a 25% en los costos anuales del caso estudiado.

Como es de esperar, para los sistemas fotovoltaicos hasta 200 kWp de potencia de instalación evaluados en la ciudad de Lima, se calcula un retorno de inversión de los sistemas fotovoltaicos entre seis y siete años. En otros trabajos, como el de Villacorta et al., (2018) que obtienen un tiempo de recuperación de 6 años del capital invertido en los sistemas fotovoltaicos, considerando la evaluación para un punto de la ciudad de Arequipa. Esa leve diferencia se debe a que la producción de energía fotovoltaica obedece a ciertos factores estacionales regionales, como la irradiación solar, eficiencia y costo de los dispositivos utilizados, el periodo del proyecto considerado, entre otros.

Por otro lado, obtener los datos de demanda de energía eléctrica de la unidad consumidora se puede considerar sumamente tediosa debido a que en la actualidad no se realizan registros de consumo. Para este trabajo, se ha tenido que realizar el registro por un

periodo de 4 meses, y a partir de ello, se ha realizado el entrenamiento y validación de un modelo de previsión para obtener los datos de los meses restantes. El modelo elegido consiste en la combinación de las técnicas de Bootstrap que se usa para el alisamiento de los datos, juntamente con los modelos de redes neurales. El modelo propuesto por Zarate et al., (2018) ha obtenido buenos resultados de previsión en el presente trabajo, debido a que la validación de los resultados obtienen un 2,2 % de error porcentual (MAPE) y Prueba de Ljung–Box tiene un valor de 0,95, validando el modelo y comprobando que ello no presenta correlación o un sobre ajuste.

Capítulo VI

VI Conclusiones

Este trabajo fue muy importante para acrecentar los conocimientos del autor sobre un tema tan presente en la práctica profesional de su área de estudio. Discutir aspectos que se relacionan directamente con las redes inteligentes de energía a través de la generación distribuida y por medio del productor – consumidor de energía es de suma importancia para el proceso de desarrollo sostenible de energía. El consumidor de energía, como un nuevo componente de la red inteligente, desempeña un papel activo en la gestión de la energía a través de su actuación no solo como un consumidor tradicional, sino como un productor de energía.

Partiendo del objetivo que consistió en modelar, en base a métodos de optimización, los recursos energéticos del consumidor residencial – que al mismo tiempo es productor de energía PV, se comprobó que un aspecto muy importante es la adopción de sistemas alternativos de energía a través de la generación distribuida. Los resultados muestran una reducción de los costos anuales de energía eléctrica por medio de la utilización de energía PV. Por lo tanto, el modelado de optimización de energía en la red de energía inteligente es de suma importancia para estimar la viabilidad de la adopción del nuevo sistema de transacciones netas (NEB) que se introduce al sistema de energía eléctrico peruano.

Los registros de demanda de la unidad consumidora por 4 meses, juntamente con los datos exógenos de temperatura, fue adecuado para entrenar y validar un modelo de previsión y obtener de forma adecuada los valores de la demanda de energía para los meses siguientes, alcanzando el primer objetivo específico. Sin embargo, debido a que estas variables son particulares a cada unidad consumidora con una influencia directa de las condiciones estacionales y de consumo, es recomendable realizar el modelado de acuerdo con sus condiciones particulares que presenta cada unidad consumidora.

En respuesta al segundo objetivo específico, que consistió en realizar el cálculo del costo nivelado de energía (LCOE) y modelar el retorno de la inversión. Para las potencias de instalación de sistemas PV entre hasta 200 kWp según la minigeneración de energía, varían entre 55,40 y 53,80 Cént. S/. kWh. Es recomendable también realizar los cálculos para cada lugar específico a evaluar, ya que las variables para encontrar el costo nivelado de energía varían en función de la ubicación debido a esas condiciones particulares.

Finalmente, atendiendo al tercer objetivo específico, los resultados obtenidos a partir de la optimización de los recursos con la finalidad de reducir los costos de consumo residencial muestran que, en relación a los consumidores de la tarifas residencial de simple medición de energía – 1E, los consumidores que optan por la producción de energía PV presentan una reducción del 16, 7 % en los costos anuales de su consumo de electricidad, concluyéndose que la adopción de fuentes renovables por medio de la generación distribuida y la modalidad de comprensión de energía adoptando el NEB (*Net Energy Billing*), es muy beneficio en términos económicos y para la conservación e uso eficiente de sus recursos de energía.

VII Recomendaciones

A partir de los resultados en este trabajo, es posible notar que los impactos del productor - consumidor de energía eléctrica involucran diferentes aspectos, que plantean la posibilidad de complementación de la investigación sobre el mismo tema.

Es posible, comparar los resultados de este estudio con los resultados de las investigaciones aplicando otro sistema de facturación de la red de energía pública, por ejemplo, con el sistema de doble medición de energía – 2E, que presenta los precios de la energía estacionales de acuerdo con las horas del día (horas punta y fuera de punta).

VIII Referencias

- 1221, D. L. N. Decreto Legislativo que Mejora la Regulación de la Distribución de Electricidad para Promover el Acceso a la Energía Eléctrica en el Perú, Pub. L. No. DL 1221 (2015). Retrieved from <https://busquedas.elperuano.pe/download/url/decreto-legislativo-que-mejora-la-regulacion-de-la-distribucion-decreto-legislativo-n-1221-1291565-11>
- Adil, A. M., & Ko, Y. (2016). Socio-technical evolution of Decentralized Energy Systems: A critical review and implications for urban planning and policy. *Renewable and Sustainable Energy Reviews*, *57*, 1025–1037. <https://doi.org/10.1016/j.rser.2015.12.079>
- Alarcon-Rodriguez, A., Ault, G., & Galloway, S. (2010). Multi-objective planning of distributed energy resources: A review of the state-of-the-art. *Renewable and Sustainable Energy Reviews*, *14*(5), 1353–1366. Retrieved from <https://ideas.repec.org/a/eee/rensus/v14y2010i5p1353-1366.html>
- Alstone, P., Gershenson, D., & Kammen, D. M. (2015). Decentralized energy systems for clean electricity access. *Nature Climate Change*, *5*(4), 305–314. <https://doi.org/10.1038/nclimate2512>
- ASCE. (2017). A COMPREHENSIVE ASSESSMENT OF AMERICA'S INFRASTRUCTURE. Retrieved from <https://www.infrastructurereportcard.org/wp-content/uploads/2016/10/2017-Infrastructure-Report-Card.pdf>
- Baños, R., Manzano-Agugliaro, F., Montoya, F. G., Gil, C., Alcayde, A., Gómez, J., ... Gómez, J. (2011). *Optimization methods applied to renewable and sustainable energy: A review*. *Renewable and Sustainable Energy Reviews* (Vol. 15). Elsevier Science. Retrieved from https://econpapers.repec.org/article/eeerens/v_3a15_3ay_3a2011_3ai_3a4_3ap_3a1753-1766.htm
- Battle, C., & Ocaña, C. (2013). Electricity Regulation: Principles and Institutions (pp. 125–150). https://doi.org/10.1007/978-1-4471-5034-3_3
- Belegundu, A. D., & Chandrupatla, T. R. (2011). *OPTIMIZATION CONCEPTS AND APPLICATIONS IN ENGINEERING* (Second Ed.). Retrieved from <http://www.mne.psu.edu/Directories/Faculty/Belegundu-A.html>. <http://users.rowan.edu/~chandrupatla.www.cambridge.org>
- Bergmeir, C., Hyndman, R. J., & Koo, B. (2018). A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics & Data Analysis*, *120*, 70–83. <https://doi.org/10.1016/J.CSDA.2017.11.003>
- Biegler, L. T., & Grossmann, I. E. (2004). Retrospective on optimization. *Computers and Chemical Engineering*, *28*, 1169–1192. <https://doi.org/10.1016/j.compchemeng.2003.11.003>
- Bilgili, M., Ozbek, A., Sahin, B., & Kahraman, A. (2015). An overview of renewable electric power capacity and progress in new technologies in the world. *Renewable and Sustainable Energy Reviews*, *49*, 323–334. <https://doi.org/10.1016/J.RSER.2015.04.148>
- Bystron, I., Rakic, P., Molnár, Z., & Blakemore, C. (2006). The first neurons of the human cerebral cortex. *Nature Neuroscience*, *9*(7), 880–886. <https://doi.org/10.1038/nn1726>

- CanadianSolar. (2018). *MAXPOWER*. Retrieved from <https://deltavolt.pe/documentos/canadian-solar-datasheet-maxpower-CS6U-P.pdf>
- Couture, T., & Gagnon, Y. (2010). An analysis of feed-in tariff remuneration models: Implications for renewable energy investment. *Energy Policy*, *38*(2), 955–965. <https://doi.org/10.1016/J.ENPOL.2009.10.047>
- Dakin, R. J. (1965). A tree-search algorithm for mixed integer programming problems. *The Computer Journal*, *8*(3), 250–255. <https://doi.org/10.1093/comjnl/8.3.250>
- Dasgupta, D., & McGregor, D. R. (1992). Designing application-specific neural networks using the structured genetic algorithm. In *[Proceedings] COGANN-92: International Workshop on Combinations of Genetic Algorithms and Neural Networks* (pp. 87–96). IEEE Comput. Soc. Press. <https://doi.org/10.1109/COGANN.1992.273946>
- de Oliveira, E. M., & Cyrino Oliveira, F. L. (2018). Forecasting mid-long term electric energy consumption through bagging ARIMA and exponential smoothing methods. *Energy*, *144*, 776–788. <https://doi.org/10.1016/J.ENERGY.2017.12.049>
- Deb, K. (2001). *Multi-objective optimization using evolutionary algorithms*. John Wiley & Sons. Retrieved from <https://www.wiley.com/en-us/Multi+Objective+Optimization+using+Evolutionary+Algorithms-p-9780471873396>
- Debnath, K. B., & Mourshed, M. (2018). Forecasting methods in energy planning models. *Renewable and Sustainable Energy Reviews*, *88*, 297–325. <https://doi.org/10.1016/J.RSER.2018.02.002>
- ECREEE. (2006). *Simplified methodology to calculate FiT*. Retrieved from http://www.ecreee.org/sites/default/files/event-att/4._iii_-_simplified_method_calculate_fit.pdf
- Eid, C., Reneses Guillén, J., Frías Marín, P., & Hakvoort, R. (2014). The economic effect of electricity net-metering with solar PV: Consequences for network cost recovery, cross subsidies and policy objectives. *Energy Policy*, *75*, 244–254. <https://doi.org/10.1016/J.ENPOL.2014.09.011>
- Enel. (2018a). Medidores inteligentes de energía: nueva tecnología, mayor control - enel.pe. Retrieved January 2, 2019, from <https://www.enel.pe/es/sostenibilidad/medidores-inteligentes-de-energia-nueva-tecnologia-mayor-control.html>
- Enel. (2018b). Pliego Tarifario Máximo del Servicio Público de Electricidad. Retrieved December 31, 2018, from <http://www2.osinergmin.gob.pe/tarifas/electricidad/PliegosTarifariosUsuarioFinal.aspx?Id=150000>
- Erdinc, O., Uzunoglu, M., Erdinc, O., & Uzunoglu, M. (2012). *Optimum design of hybrid renewable energy systems: Overview of different approaches*. *Renewable and Sustainable Energy Reviews* (Vol. 16). Elsevier Science. Retrieved from https://econpapers.repec.org/article/eeerensus/v_3a16_3ay_3a2012_3ai_3a3_3ap_3a1412-1425.htm
- Fathima, A. H., & Palanisamy, K. (2015). Optimization in microgrids with hybrid energy systems – A review. *Renewable and Sustainable Energy Reviews*, *45*, 431–446. <https://doi.org/10.1016/J.RSER.2015.01.059>
- Felix, R., & Unsihuay-Vila, C. (2018). A Model to optimize Mix Power Generation Selection

- of Distributed Renewable Plants for Expansion Planning with Reliability Criteria: An Application in Puno, Peru. In *2018 IEEE PES Transmission & Distribution Conference and Exhibition - Latin America (T&D-LA)* (pp. 1–5). IEEE. <https://doi.org/10.1109/TDC-LA.2018.8511762>
- Ferster, D., & Spruston, N. (1995). Cracking the neuronal code. *Science (New York, N.Y.)*, *270*(5237), 756–757. <https://doi.org/10.1126/SCIENCE.270.5237.756>
- Floudas, C. A. (1995). *Nonlinear and mixed-integer optimization: fundamentals and applications*. Oxford University Press.
- Fourer, R., Gay, D. M., & Kernighan, B. W. (1990). A Modeling Language for Mathematical Programming. *Management Science*, *36*(5), 519–554. <https://doi.org/10.1287/mnsc.36.5.519>
- Francisco Ismodes Mezzano. Autorizan publicación de proyecto de Decreto Supremo que aprueba el Reglamento de la Generación Distribuida - RESOLUCION MINISTERIAL - N° 292-2018-MEM/DM - PODER EJECUTIVO - ENERGIA Y MINAS, Pub. L. No. N° 292-2018-MEM/DM (2018). Retrieved from <https://busquedas.elperuano.pe/normaslegales/autorizan-publicacion-de-proyecto-de-decreto-supremo-que-apr-resolucion-ministerial-no-292-2018-memdm-1675717-1/>
- Gamarra, C., & Guerrero, J. M. (2015). Computational optimization techniques applied to microgrids planning: A review. *Renewable and Sustainable Energy Reviews*, *48*, 413–424. <https://doi.org/10.1016/j.rser.2015.04.025>
- GAMS. (2018). GAMS Documentation Center. Retrieved December 27, 2018, from <https://www.gams.com/latest/docs/>
- Gardner, M. ., & Dorling, S. . (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric Environment*, *32*(14–15), 2627–2636. [https://doi.org/10.1016/S1352-2310\(97\)00447-0](https://doi.org/10.1016/S1352-2310(97)00447-0)
- Georgilakis, P. S., & Hatziargyriou, N. D. (2013). Optimal Distributed Generation Placement in Power Distribution Networks: Models, Methods, and Future Research. *IEEE Transactions on Power Systems*, *28*(3), 3420–3428. <https://doi.org/10.1109/TPWRS.2012.2237043>
- Ghiani, E., Serpi, A., Pilloni, V., Sias, G., Simone, M., Marcialis, G., ... Pegoraro, P. A. (2018). A Multidisciplinary Approach for the Development of Smart Distribution Networks. *Energies*, *11*(10), 2530. <https://doi.org/10.3390/en11102530>
- Gómez, T. (2013). Electricity Distribution (pp. 199–250). https://doi.org/10.1007/978-1-4471-5034-3_5
- Grossmann, I. E., & Biegler, L. T. (2004). Part II. Future perspective on optimization. *Computers & Chemical Engineering*, *28*(8), 1193–1218. <https://doi.org/10.1016/j.compchemeng.2003.11.006>
- Hammerstrom, D. J. (2007). AC Versus DC Distribution Systems Did We Get it Right? *Undefined*. Retrieved from <https://www.semanticscholar.org/paper/AC-Versus-DC-Distribution-SystemsDid-We-Get-it-Hammerstrom/78bf550b15b0166d2c0520056fbe1965ac05dc8d>
- Hinton, G., Osindero, S., Welling, M., & Teh, Y.-W. (2006). Unsupervised Discovery of Nonlinear Structure Using Contrastive Backpropagation. *Cognitive Science*, *30*(4), 725–

731. https://doi.org/10.1207/s15516709cog0000_76
- Hirsh, R. F. (1999). *Power loss: the origins of deregulation and restructuring in the American electric utility system*. MIT Press.
- Holland, J. H. (John H. (1992). *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. MIT Press.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences of the United States of America*, 79(8), 2554–2558. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/6953413>
- Hyndman, R. J., & Athanasopoulos, G. (2014). *Forecasting: principles and practice*. OTEXTS.COM. Retrieved from <http://otexts.com/fpp/>
- Jain, R. K., Smith, K. M., Culligan, P. J., & Taylor, J. E. (2014). Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy. *Applied Energy*, 123, 168–178. <https://doi.org/10.1016/J.APENERGY.2014.02.057>
- Keirstead, J., & Shah, N. (2013). *Urban energy systems: an integrated approach*. Routledge.
- Khan, G. M. (2018). Artificial Neural Network (ANNs). In Polish Academy of Sciences (Ed.), *Evolution of Artificial Neural Development* (725th ed., pp. 39–55). Warsaw, Poland: Springer, Cham. https://doi.org/10.1007/978-3-319-67466-7_4
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43(1), 59–69. <https://doi.org/10.1007/BF00337288>
- Kohonen, T. (2001). *Self-organizing maps*. Springer.
- Kohonen, T., & Somervuo, P. (2002). How to make large self-organizing maps for nonvectorial data. *Neural Networks: The Official Journal of the International Neural Network Society*, 15(8–9), 945–952. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/12416685>
- Kuster, C., Rezgui, Y., & Mourshed, M. (2017). Electrical load forecasting models: A critical systematic review. *Sustainable Cities and Society*, 35, 257–270. <https://doi.org/10.1016/J.SCS.2017.08.009>
- Lacchini, C. (2017). *Análise econômica de sistemas fotovoltaicos residenciais no contexto brasileiro, com foco nos indicadores financeiros e nas tarifas locais de energia elétrica*. Retrieved from <https://repositorio.ufsc.br/handle/123456789/181239>
- Lacchini, C., & Dos Santos, J. C. V. (2013). Photovoltaic energy generation in Brazil – Cost analysis using coal-fired power plants as comparison. *Renewable Energy*, 52, 183–189. <https://doi.org/10.1016/J.RENENE.2012.10.033>
- Laloux, D., & Rivier, M. (2013). Technology and Operation of Electric Power Systems (pp. 1–46). https://doi.org/10.1007/978-1-4471-5034-3_1
- Lesourd, J.-B. (2001). Solar photovoltaic systems: the economics of a renewable energy resource. *Environmental Modelling & Software*, 16(2), 147–156. [https://doi.org/10.1016/S1364-8152\(00\)00078-5](https://doi.org/10.1016/S1364-8152(00)00078-5)
- Ma, L., Liu, N., Zhang, J., Tushar, W., & Yuen, C. (2016). Energy Management for Joint

- Operation of CHP and PV Prosumers Inside a Grid-Connected Microgrid: A Game Theoretic Approach. *IEEE Transactions on Industrial Informatics*, 12(5), 1930–1942. <https://doi.org/10.1109/TII.2016.2578184>
- Maass, W., Schnitger, G., & Sontag, E. D. (1991). On the Computational Power of Sigmoid versus Boolean Threshold Circuits. In *Proceedings of the 32nd Annual IEEE Symposium on Foundations of Computer Science* (pp. 767–776). Retrieved from <https://igi-web.tugraz.at/PDF/58b.pdf>
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- NEOS Server. (2018). NEOS Server: State-of-the-Art Solvers for Numerical Optimization. Retrieved December 27, 2018, from <https://neos-server.org/neos/>
- NREL. (2018). NSRDB Data Viewer v3.0.1. Retrieved from <https://maps.nrel.gov/nsrdb-viewer/?aL=f69KzE%255Bv%255D%3Dt&bL=groad&cE=0&lR=0&mC=-20.427012814257385%2C-42.703857421875&zL=7>
- Osinerg. (2001). *Opciones Tarifarias y Condiciones de Aplicación de las Tarifas a Usuario Final*. Retrieved from <http://www.osinergmin.gob.pe/Resoluciones/pdf/2005/OSINERG No.236-2005-OS-CD-Norma.pdf>
- Osinergmin. (2018). Regulación Tarifaria. Retrieved December 31, 2018, from <http://www.osinergmin.gob.pe/seccion/institucional/regulacion-tarifaria>
- Ouyang, X., & Lin, B. (2014). Levelized cost of electricity (LCOE) of renewable energies and required subsidies in China. *Energy Policy*, 70, 64–73. <https://doi.org/10.1016/J.ENPOL.2014.03.030>
- Perez, E. J. Z., Fernández, M. P., & Motta, A. L. T. S. da. (2018). Performance Analysis of Bagging Feed-Forward Neural Network for Forecasting Building Energy Demand. *Current Journal of Applied Science and Technology*, 30(2), 1–12. <https://doi.org/10.9734/CJAST/2018/44836>
- Pokharel, K., Mokhtar, M., & Howe, J. (2012). A Multi-Objective Planning Framework for Optimal Integration of Distributed Generations. Retrieved from <http://clouk.uclan.ac.uk/5971/>
- Pyrgou, A., Kylili, A., & Fokaides, P. A. (2016). The future of the Feed-in Tariff (FiT) scheme in Europe: The case of photovoltaics. *Energy Policy*, 95, 94–102. <https://doi.org/10.1016/J.ENPOL.2016.04.048>
- R Core Team (2018). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. (n.d.). Retrieved from <https://www.r-project.org/>
- Rabbani, M., & Dolatkhah, M. (2018). Integration of Demand-Side Management Programs and Supply-Side Alternatives for Decentralized Energy Planning: An Analysis of Energy Import and Export Effects Integration of Demand-Side Management Programs and Supply-Side Alternatives. (D. Mehdi Khosrow-Pour, U. Steve Clarke, University of Hull, U. Murray E. Jennex, San Diego State University, U. Annie Becker, Florida Institute of Technology, & F. Ari-Veikko Anttiroiko, University of Tampere, Eds.), pp. 252–270. <https://doi.org/10.4018/978-1-5225-3817-2.ch013>

- Rob Hyndman;, George Athanasopoulos;, Christoph Bergmeir;, Gabriel Caceres;, Leanne Chhay;, Mitchell O'Hara-Wild;, ... Zhenyu Zhou. (2018). Package “forecast”: Forecasting Functions for Time Series and Linear Models. CRAN. Retrieved from <https://orcid.org/0000-0002-3665-9021>
- Salpakari, J., & Lund, P. (2016). Optimal and rule-based control strategies for energy flexibility in buildings with PV. *Applied Energy*, 161, 425–436. <https://doi.org/10.1016/J.APENERGY.2015.10.036>
- Sastre, C. M., González-Arechavala, Y., & Santos, A. M. (2015). Global warming and energy yield evaluation of Spanish wheat straw electricity generation – A LCA that takes into account parameter uncertainty and variability. *Applied Energy*, 154, 900–911. <https://doi.org/10.1016/J.APENERGY.2015.05.108>
- Shao, Z., Chao, F., Yang, S.-L., & Zhou, K.-L. (2017). A review of the decomposition methodology for extracting and identifying the fluctuation characteristics in electricity demand forecasting. *Renewable and Sustainable Energy Reviews*, 75, 123–136. <https://doi.org/10.1016/J.RSER.2016.10.056>
- Villacorta, A. R., Kuong, J. L., & Mojonero, D. H. (2018). Impact Assessment of Net Metering for Residential Photovoltaic Distributed Generation in Peru. *International Journal of Renewable Energy Research (IJRER)*, 8(3), 1200–1207. Retrieved from <https://www.ijrer.com/index.php/ijrer/article/view/7093>
- Wambach, A. (2000). Payback criterion, hurdle rates and the gain of waiting. *International Review of Financial Analysis*, 9(3), 247–258. [https://doi.org/10.1016/S1057-5219\(00\)00028-4](https://doi.org/10.1016/S1057-5219(00)00028-4)
- Williams, H. P. (2013). *Model building in mathematical programming* (3rd ed.). Houston: Wiley.
- Xianyan Chen. (2017). Package “NlcOptim” Solve Nonlinear Optimization with Nonlinear Constraints. CRAN. Retrieved from <https://cran.r-project.org/web/packages/NlcOptim/NlcOptim.pdf>
- Zarate Pérez, E. J., Fernandez, M. P., Torres, A. L., & Da Motta, S. (2018). SISTEMA DE ILUMINAÇÃO RESIDENCIAL FOTOVOLÁTICA AUTÓNOMO: O CASO DE PERU. In Universidade Federal de Rio de Janeiro (Ed.), *6ª Conferência sobre Patologia e Reabilitação de Edifícios – PATORREB* (p. 10). Rio de Janeiro: NPPG. <https://doi.org/ISBN 978-85-60270-03-3>