



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

**DISEÑO DE UN SISTEMA DE GESTIÓN DE DEMANDA BASADO EN LÓGICA
DIFUSA PARA MICRO-REDES**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERA CIVIL ELECTRICISTA

**TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA
INGENIERÍA, MENCIÓN ELÉCTRICA**

FERNANDA ISABEL ÁVILA SWINBURN

PROFESORA GUÍA:
DORIS SÁEZ HUEICHAPAN

MIEMBROS DE LA COMISIÓN:
GUILLERMO JIMÉNEZ ESTÉVEZ
CLAUDIO CAÑIZARES

SANTIAGO DE CHILE
SEPTIEMBRE 2013

“Diseño de un Sistema de Gestión de Demanda Basada en Lógica Difusa para Micro-redes”

Debido a la geografía Chilena, aún existen localidades aisladas de los cuatro grandes sistemas eléctricos que proveen energía al país. Considerando esta situación y el hecho de que Chile posee abundantes recursos renovables no convencionales para generar energía eléctrica, se plantea la posibilidad de instalar centrales de generación distribuida para estas localidades, de manera de robustecer los sistemas principales ya existentes.

El Centro de Energía de la Universidad de Chile, instaló en 2010 una micro-red con generación distribuida en la localidad de Huatacondo, región de Tarapaca, que incorpora recursos renovables. Dicha comunidad, contaba con 10 horas diarias de energía previo a la instalación de la micro-red. Ésta micro-red está diseñada para operar con un EMS (Energy Management System), que realiza los despachos de las unidades, de manera de optimizar los costos de generación. Una de las entradas a este sistema corresponde a la predicción de demanda y además incorpora un sistema de gestión de demanda.

El primero de los objetivos de esta tesis es el diseño del bloque de predicción de demanda, para lo cual se utilizaron modelos difusos de Takagi y Sugeno, tomando en cuenta el comportamiento no lineal que presenta la demanda. El modelo está diseñado para entregar las predicciones que el EMS necesita, es decir, para un horizonte de 2 días. Al derivar el modelo, se incluye a las etapas de identificación, un análisis de estabilidad basada en los teoremas Tanaka y Sugeno (1990). El modelo final consta de cuatro reglas y 96 regresores, es decir, la demanda futura depende de la demanda del día anterior. Como resultado, se obtiene un modelo que logra entregar predicciones para horizontes de dos días, con errores entorno al 14%. También se analizó la predicción utilizando el optimizador del EMS, la predicción con modelo difuso tenía un error 11% menor a la predicción usada originalmente, lo que se tradujo en una disminución del 15% de los costos para la optimización a dos días. El segundo objetivo corresponde a desarrollar una metodología para modelar la variación del consumo ante las señales de gestión de demanda, utilizando para esto modelos difusos de Mamdani. La base de reglas se construyó a partir de la información de encuestas realizadas a los habitantes de Huatacondo, a los que se les preguntó sobre su consumo eléctrico habitual y cómo este cambiaría para diferentes señales de gestión. A partir de las encuestas se realizó un perfil base para cada casa los que se compararon con los cambios que dijeron realizarían para diferentes señales de gestión, a partir de esto se extrajeron siete reglas difusas. Los conjuntos de entrada al modelo corresponden a la hora y la señal de gestión, mientras que la salida es la variación esperada en el consumo.

Finalmente, se utilizan intervalos difusos para determinar el rango dinámico para el factor de desplazamiento de carga. Esto se probó en el EMS, utilizando dos intervalos de distinta amplitud y comparándolos con el caso sin desplazamiento de carga, obteniéndose que a mayor amplitud del intervalo, los costos disminuyen hasta en un 27%.

Agradecimientos

Debo partir agradeciendo a mis padres, Jaime y Jacqueline, ya que son ellos los que me han dado las herramientas y facilidades para completar este episodio de mi vida. Gracias por respetar mis decisiones, por soportar mi idiotez en los momentos de estrés y sobre todo por ser mi hogar.

Agradezco a toda mi familia; tatas, tíos y primos por creer en mí más de lo que yo podría. También especialmente a mi abuelita Clara por rezar por mí y ser el nexa para conseguir todos los pequeños milagros que tanto me ayudaron durante el camino.

A mis amigas de la vida; Ange, Tere, Sole, Cony y Andreda. Gracias por ser parte de mi vida desde hace tanto tiempo y seguir ahí, por darle diversidad a mi vida además de infinita locura y apoyo. A todos mis amigos de la U; Con, Camilo, Caro, Gaby, Gorro, Shaggy, Pau, Dharma, Ancla, gracias por todos los buenos momentos que hemos compartido y por llevarme por el camino de la sabiduría durante todos estos años. A los eléctricos que participaron en algún jueves eléctrico, fue genial conocerlos lejos de los libros, TI's y cables. También gracias a mi pololo, Alejandro, por ser uno de mis principales soportes estos últimos meses, llegaste a mi vida en el momento perfecto.

Agradezco a los profesores que fueron parte de mi formación, en especial a mi profesor guía, Doris Sáez, a quien agradezco todas las oportunidades que no esperaba, la especial preocupación y la buena onda durante todo el desarrollo de la tesis.

También doy gracias al Centro de Energía de la Universidad de Chile, en especial a Fernando Lanas por responder mis insistentes preguntas y a la comunidad de Huatacondo por ser parte importante de mi trabajo.

Finalmente, agradezco el apoyo para el desarrollo de la tesis de magíster a: CONICYT (becario de magíster), proyecto FONDECYT no. 1110047, Instituto Sistemas Complejos de Ingeniería ICM: P-05-004-F y Solar Energy Research Center (SERC) CONICYT: FBO16, CONICYT/FONDAP/15110019.

1 Tabla de Contenido

2	Introducción	1
2.1	Objetivos.....	2
2.1.1	Objetivos generales	2
2.1.2	Objetivos específicos.....	2
2.2	Alcances.....	2
2.3	Estructura de la tesis	3
3	Antecedentes y situación actual	4
3.1	Micro-redes.....	4
3.2	Caso de estudio: Huatacondo	5
3.3	Discusión	10
4	Estado del arte	11
4.1	Demanda eléctrica y micro-redes	11
4.2	Predicción de demanda eléctrica	12
4.2.1	Predicción de demanda a corto plazo	12
4.2.2	Predicción de demanda en micro-redes.....	15
4.2.3	Discusión.....	18
4.3	Gestión de demanda.....	18
4.3.1	Técnicas de gestión de demanda	19
4.3.2	Gestión de demanda en micro-redes	22
4.3.3	Discusión.....	32
5	Predicción de demanda basada en modelación difusa de Takagi y Sugeno.....	34

5.1	Modelos difusos de Takagi y Sugeno.....	34
5.2	Metodología de identificación difusa	35
5.3	Análisis de estabilidad	38
5.3.1	Estabilidad según Lyapunov	38
5.3.2	Métodos para el análisis de estabilidad	39
5.3.3	Metodología propuesta para el análisis de estabilidad de modelos difusos	42
5.4	Desarrollo de un módulo de predicción de demanda para utilizar en un sistema de gestión de energía (EMS).....	44
5.4.1	Caso de estudio.....	45
5.4.2	Identificación del modelo.....	45
5.4.3	Resultados	50
5.4.4	Discusión.....	52
5.5	Predicción a j-pasos	53
5.5.1	Discusión.....	58
5.6	Análisis comparativo	59
5.6.1	Discusión.....	60
5.7	Conclusiones del capítulo.....	60
6	Gestión de demanda	61
6.1	Metodología propuesta para determinar el rango de desplazamiento dinámico de carga, utilizando intervalos difusos.....	61
6.1.1	Intervalos difusos	62
6.1.2	Intervalo difuso a j pasos.....	64
6.1.3	Cálculo del rango para factor de desplazamiento de carga	68
6.1.4	Discusión.....	72
6.2	Corrección de la predicción de demanda utilizando modelos difusos de Mamdani	73

6.2.1	Modelación difusa de Mamdani	73
6.2.2	Generación de perfil base y reglas difusas	75
6.2.3	Experimento propuesto para determinar los parámetros de los conjuntos difusos ..	80
6.2.4	Discusión	84
7	Conclusiones	85
8	Trabajo Futuro	88
9	Publicaciones y Estadía de Investigación.....	89
9.1	Publicaciones generadas	89
9.2	Estadía de Investigación	89
10	Referencias	90
11	Anexos.....	97
11.1	Anexo A	97
11.2	Anexo B	98
11.3	Anexo C	99
11.4	Anexo D	101
11.5	Anexo E	102

Índice de figuras

Figura 1: Arquitectura de una micro-red [2]	5
Figura 2: Imagen satelital de Huatacondo	6
Figura 3: Diagrama del sistema de gestión de demanda instalado en Huatacondo.....	7
Figura 4: Semáforo para gestión de demanda	9
Figura 5: Estructura de la estrategia de dos niveles para predicción de carga a corto plazo [37]..	16
Figura 6: Arquitectura del método de clasificador múltiple [41].....	17
Figura 7: Áreas de la curva de carga que pueden ser modificadas [43]	19
Figura 8: Control directo de carga aplicado en artefactos HVAC [48].....	20
Figura 9: Arquitectura MGCC [64].....	24
Figura 10: Balance de carga [66]	25
Figura 11: Comparación entre el rendimiento de los distintos tipos de programación de demanda	26
Figura 12: Costo de Producción Total [68].....	27
Figura 13: Emisiones Totales [68]	27
Figura 14: Costo de generación en un horizonte de 24 horas [69].....	28
Figura 15: Arquitectura del sistema de control ADSM [72].....	31
Figura 16: Respuesta final del sistema ADSM	31
Figura 17: Aproximación lineal con modelo de Takagi y Sugeno [78]	35
Figura 18: Identificación modelo difuso [79]	36
Figura 19: Región LMI [86].....	40
Figura 20 : Metodología para el análisis de estabilidad de modelos difusos de Takagi y Sugeno	44
Figura 21: Demanda eléctrica promedio durante Marzo 2011 en Huatacondo.....	45
Figura 22: Metodología de identificación utilizada para el modelo de predicción de demanda....	46

Figura 23: RMSE para el modelo TKS11 en función del número de reglas.....	48
Figura 24: RMSE para el modelo TKS21 en función del número de reglas.....	48
Figura 25: Predicción a 192 pasos.....	50
Figura 26: Predicción de demanda utilizada en el optimizador	51
Figura 27: Diagrama módulo de predicción a j pasos.....	53
Figura 28: RMSE para predicción a J pasos en micro-red de Huatacondo.....	54
Figura 29: Error de predicción para 192 pasos	55
Figura 30: Error de predicción para 96 pasos	56
Figura 31: Error de predicción para 4 pasos	56
Figura 32: Comparación entre conjunto de entrenamiento y día perteneciente al conjunto con alto error (21-Abril).....	57
Figura 33: EMS integrando intervalo difuso.....	62
Figura 34: Método A.....	65
Figura 35: Método B	65
Figura 36: Parámetros alpha para método A.....	67
Figura 37: Parámetros alpha para método B	67
Figura 38: Intervalo difuso con distintos niveles de confianza para un horizonte de 192 pasos ...	67
Figura 39: Intervalo realizado con $a=1$ (Nivel de confianza=60%).....	68
Figura 40: Intervalo realizado con $a=4.5$ (Nivel de confianza =97%).....	69
Figura 41: Rango para el factor de desplazamiento de demanda.....	69
Figura 42: Unidades de la micro-red sin control de demanda.....	71
Figura 43: Unidades de la micro-red con un desplazamiento estático de demanda del 5%	71
Figura 44: Unidades de la micro-red para un desplazamiento basado en el intervalo construido con $\alpha=1$	71

Figura 45: Unidades de la micro-red para un desplazamiento basado en el intervalo construido con $\alpha=4.5$	72
Figura 46: Diagrama sistema difuso de Mamdani [96].....	73
Figura 47: Diagrama para la modelación del comportamiento de los consumidores	75
Figura 48: Conjuntos difusos para las luces del semáforo	76
Figura 49: Conjuntos difusos para el horario	76
Figura 50: Conjuntos difusos para la variación de consumo	76
Figura 51: Procedimiento para el cálculo de pulsos.....	78
Figura 52: Perfil base de la casa 5 asociada al poste 28.....	79
Figura 53: Semáforo 1	79
Figura 54: Semáforo 2.....	79
Figura 55: Semáforo 3.....	79

Índice de tablas

Tabla 1: Características de las unidades que componen la micro-red [5].....	6
Tabla 2: Significado de las luces del semáforo	9
Tabla 3: Conjuntos para realización del modelo.....	47
Tabla 4: RMSE para el conjunto de validación utilizando TKS21	49
Tabla 5: RMSE para predicción a 192 pasos	49
Tabla 6: Comparación de costos para las distintas predicciones	52
Tabla 7: RMSE Promedio	55
Tabla 8: RMSE para modelo entrenado 7, 15 o 30 días.....	57
Tabla 9: MAPE para modelos entrenados cada 7, 15 o 30 días	58
Tabla 10: Comparación con red neuronal utilizando RMSE.	59
Tabla 11: Comparación con red neuronal utilizando MAPE.	59
Tabla 12: Costos para diferentes rangos de desplazamiento a un horizonte de 2 días.....	70
Tabla 13: Consumos típicos	77
Tabla 14: Base de reglas difusas resultantes	79
Tabla 15: Cromosomas de los conjuntos difusos	82
Tabla 16: Rangos para el valor de los cromosomas de los conjuntos de “Horario”	82
Tabla 17: Promedio de variación de consumo extraído desde encuestas.....	83
Tabla 18: Rangos para el valor de los cromosomas de los conjuntos de “variación de consumo”.....	83

2 Introducción

Debido a las condiciones geográficas de Chile, aún existen comunidades aisladas de los cuatro sistemas eléctricos que distribuyen energía dentro del país. Las micro-redes inteligentes basadas en energías renovables, representan una solución para este problema, tomando en cuenta la abundancia de recursos que existen para generar energías renovables no convencionales. Con este pensamiento, el Centro de Energía de la Universidad de Chile instaló en 2010 una micro-red de generación distribuida en la localidad de Huatacondo, ubicada en la primera región de Tarapacá, la cual incorpora recursos renovables (energía solar y eólica). Antes de la instalación de la micro-red, esta localidad contaba con tan solo 10 horas de energía diaria, situación que cambió, contando actualmente con electricidad las 24 horas del día. La micro-red instalada opera actualmente con un sistema de gestión de energía (EMS: Energy Management System), el cual realiza los despachos de las unidades, minimizando los costos de generación. Las entradas del EMS son: predicción de consumo, predicción de variables climáticas y el estado de carga de las baterías.

El EMS tiene incorporado un sistema de gestión de demanda, basado en “respuesta de la demanda”. Este sistema consiste en enviar señales lumínicas a los consumidores a través de semáforos instalados en sus hogares, con el fin de que disminuyan, aumenten o mantengan su consumo de manera de tener un despacho óptimo. Con respecto a este sistema, en este trabajo se abordan dos temas; el cálculo del rango en que la demanda puede desplazarse y el efecto que tienen las señales de gestión de demanda sobre la predicción.

Para el primer tema, se utilizarán de intervalos difusos para determinar, a base de datos históricos, el rango dinámico. Este rango proporciona los límites al optimizador para el factor de desplazamiento de carga, del cual dependen las señales que se envían a los consumidores.

El segundo tema se basa en que se espera que los consumidores modifiquen su consumo al ver las señales de gestión de demanda, pero no se sabe en cuánto, lo que también afecta a la predicción, es por esto que se presentará una metodología para modelar la variación del consumo utilizando modelos difusos de Mamdani.

Las estrategias de gestión de demanda sirven para mantener el equilibrio entre generación y demanda, lo cual es de vital importancia para micro-redes, donde los recursos energéticos presentan fluctuaciones. Además, para mantener este equilibrio, es importante tener una predicción de demanda confiable, por lo que también se realizará un modelo para esto, utilizando modelación difusa de Takagi y Sugeno. Además, a las etapas típicas de identificación, se agregó un bloque de análisis de estabilidad basado en el estudio de las matrices de estado generadas por cada regla difusa.

2.1 Objetivos

A continuación se listan los objetivos generales y específicos del trabajo desarrollado en esta tesis.

2.1.1 Objetivos generales

- Diseñar técnicas para robustecer el sistema de gestión de demanda para micro-redes, que además se constituyan como datos de entrada para las predicciones de demanda.
- Implementar un modelo de predicción de demanda para micro-redes.

2.1.2 Objetivos específicos

- Diseñar un modelo difuso para la predicción de consumo eléctrico con un horizonte de dos días.
- Diseñar un procedimiento de identificación del modelo de predicción, que incluya análisis de estabilidad.
- Analizar y modelar el rango de desplazamiento dinámico de carga, para el optimizador de la micro-red, a partir de datos históricos de demanda eléctrica.
- Formular una metodología para modelar el comportamiento de los consumidores ante las señales enviadas, con el fin de corregir la predicción de demanda.

2.2 Alcances

En esta tesis se desarrollará un modelo para la predicción de demanda en micro-redes, utilizando como entrada los datos de demanda de un día pasado (96 regresores), para pronosticar la demanda a un horizonte de 2 días (192 pasos). La predicción se realizará mediante modelación difusa de Takagi y Sugeno, a cuyo proceso de identificación se incluirá una etapa de análisis de estabilidad, la que será programada en Matlab. El modelo de predicción también se programará en Matlab, y para estudiar su desempeño se utilizarán datos históricos de la micro-red instalada en Huatacondo y se comparará con un modelo de predicción basado en redes neuronales, también diseñado para la micro-red de Huatacondo.

En relación a la gestión de demanda, se abarcarán dos temas principales en esta tesis; el primero corresponde a calcular el rango dinámico para el factor de desplazamiento de carga, utilizado por el optimizador de la micro-red para determinar las señales de gestión de demanda. Para determinar dicho rango, se utilizarán intervalos difusos, lo que considera desarrollar dos métodos para predecir los intervalos a “j” pasos, ya que el optimizador trabaja con horizonte de 192 pasos. Uno de estos métodos, elegido por su desempeño, será el utilizado para calcular el rango de desplazamiento de demanda 192 pasos, con datos históricos y se probará este rango dinámico en el simulador del optimizador del sistema de gestión de energía.

El segundo tema en relación a la gestión de demanda, corresponde a los cambios que producen las señales en el patrón de demanda, por lo cual se planteará una metodología para modelar el efecto que tienen las señales de gestión de demanda sobre la predicción de ésta, utilizando modelos difusos de Mamdani.

2.3 Estructura de la tesis

El informe de esta tesis se estructura como sigue; en el primer capítulo se presenta la introducción al trabajo, planteando alcances y objetivos de la tesis y el camino a seguir para el buen término de ésta.

En el segundo capítulo se plantea el problema a abordar, para esto se inicia con la presentación del concepto de micro-redes, luego se detalla la micro-red instalada en Huatacondo con todas sus componentes y se especifican los aspectos que el trabajo de ésta tesis pretende mejorar.

La tercera sección corresponde al estado del arte, donde se tratan los dos temas principales de esta tesis, predicción y gestión de demanda. Se detallan conceptos relacionados, clasificaciones y se enfatizan los trabajos aplicados en el campo de las micro-redes, tanto para gestión de demanda como para la predicción de ésta.

A continuación, el cuarto capítulo trata sobre el modelo de predicción de demanda desarrollado. Se presentan los modelos difusos de Takagi y Sugeno, los análisis de estabilidad que se han realizado en otros trabajos a este tipo de modelos y la técnica que se incluirá en las etapas de identificación que se utiliza en este trabajo. Luego, se detalla cómo se desarrolló el módulo de predicción de demanda y los resultados que se obtuvieron con un set de datos históricos de la comunidad de Huatacondo. También se detallan las etapas para realizar predicción a “j” pasos y los resultados que se obtuvieron de comparar la predicción realizada con una efectuada anteriormente utilizando redes neuronales.

El quinto capítulo comprende los trabajos realizados sobre gestión de demanda. Se presenta la metodología propuesta para determinar el rango de desplazamiento dinámico de carga, para lo cual primero se desarrolla el concepto de intervalos difusos. En segundo lugar, se presentan dos metodologías para calcular intervalo difuso a “j” pasos, lo que se utiliza para calcular el rango a 192 para ser utilizado en el optimizador, presentando finalmente los resultados de esta prueba y discutiendo los resultados.

Finalmente, en el último capítulo, se presentan las conclusiones del trabajo realizado de acuerdo con los objetivos y alcances, además se plantean ideas para trabajos futuros, relacionadas con el trabajo desarrollado en esta tesis.

3 Antecedentes y situación actual

En la presente sección, se explica el concepto de micro-redes, para luego especificar el caso de estudio, que corresponde a la micro-red instalada en la comunidad de Huatacondo. Se describirán características geográficas y sociales de dicha comunidad, como también las características técnicas de la micro-red instalada.

3.1 Micro-redes

La generación distribuida ha cobrado importancia debido a las bajas emisiones y los bajos costos que supone. Entre esta tecnología se cuentan las turbinas a gas, celdas de combustible, micro-turbinas y paneles fotovoltaicos. Para evitar los problemas que estos generadores pueden acarrear, en [1] se propone utilizar estos generadores y su cargas asociadas como subsistemas que puedan aislarse de la red de distribución. A estos subsistemas se les denomina micro-redes.

Las micro-redes corresponden a un conjunto de cargas y pequeños generadores, operando como un solo sistema controlable, que proveen de energía y/o calefacción a su área local asociada. Estas pueden estar conectadas o no a la red principal, pudiendo, en el primer caso, aislarse en frente al existencia de problemas de distribución. Las fuentes de energía utilizadas en este tipo de red corresponden a generadores pequeños ($<100[\text{kW}]$) con interfaces electrónicas, como micro-turbinas, paneles fotovoltaicos y celdas de combustibles [2].

Para la operación segura de un micro-red que cuenta con dos o más fuentes de generación distribuida, se requiere de la utilización de un sistema de gestión de energía, necesario para operar en modo autónomo. En el caso de las micro-redes, es más crítica una respuesta rápida que para una gran red interconectada, esto debido a la presencia de múltiples generadores distribuidos con distintas capacidades de generación y la respuesta de interfaces electrónicas que podrían afectar la estabilidad del sistema [3].

En la Figura 1 se observa la arquitectura básica de una micro-red, la cual está conectada al sistema de distribución a través de un dispositivo de separación, que usualmente corresponde a un interruptor.

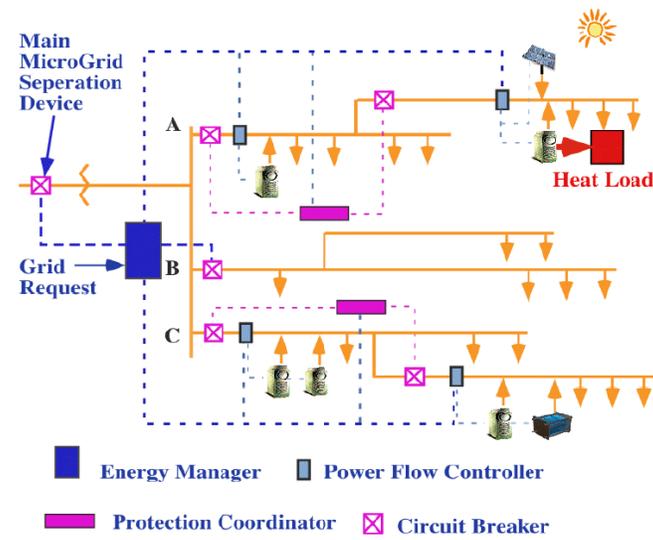


Figura 1: Arquitectura de una micro-red [2]

3.2 Caso de estudio: Huatacondo

Huatacondo es una comunidad rural ubicada a 230km al sureste de la ciudad de Iquique, en la región de Tarapacá. La población de Huatacondo bordea los 100 habitantes, mayormente gente de edad avanzada, estando la mayor parte de sus prácticas ligadas fuertemente a la religión católica. Durante festividades tradicionales, como la fiesta de la tirana, de las cruces, el carnaval y fiestas patrias, la población puede llegar a las 500 personas [4]. Esta comunidad se encuentra desconectada del sistema interconectado del norte grande y previo a la instalación de la micro-red, la comunidad contaba con un suministro de energía desde las 14:00 horas hasta las 24:00 horas de lunes a viernes y desde las 16:00 horas hasta las 24:00 horas los fines de semana, obteniendo la energía desde un grupo generador diésel, cuyo combustible es proporcionado por la municipalidad. En la Figura 2 se presenta una imagen satelital de Huatacondo, extraída desde Google Earth, en la cual se aprecia la característica de oasis de la localidad. Esto es aprovechado por los habitantes, quienes practican la agricultura, plantando diversas frutas y verduras para su consumo personal o para el comercio en pequeña escala.

Actualmente, la comunidad de Huatacondo cuenta con energía eléctrica durante las 24 horas del día, gracias a la micro-red inteligente instalada en el año 2010 por el Centro de Energía de la Universidad de Chile, la cual está compuesta por paneles fotovoltaicos, un generador diésel, una turbina eólica y un banco de baterías. Además, el poblado cuenta con una bomba de agua, la cual podría utilizarse para gestión de demanda como carga controlable en trabajos futuros.



Figura 2: Imagen satelital de Huatacondo

El trabajo realizado se basa en la micro-red instalada en la comunidad de Huatacondo, la cual utiliza principalmente energías renovables no convencionales. Las unidades que componen la micro-red tienen las características que se muestran en la Tabla 1.

Tabla 1: Características de las unidades que componen la micro-red [5]

Parámetros	Valor
Potencia panel fotovoltaico	22 [kW]
Potencia turbina eólica	2.5 [kW]
Potencia máxima baterías	150 [kW]
Capacidad del banco de baterías	150 [kWh]
Potencia máxima del generador diésel	120 [kW]
Potencia mínima del generador diésel	10 [kW]

El problema asociado a las fuentes de energías renovables no convencionales es la fluctuación que presentan, debido a que dependen generalmente de las condiciones climáticas que varían minuto a minuto. Es por esto que las unidades generadoras de la micro-red deben coordinarse, para lo cual en [5] se propone la utilización de un sistema de gestión de energía (EMS) que optimice la operación de un conjunto de unidades de generación y cargas, utilizando sistemas de comunicación, monitoreo y control para aplicar el pre-despacho. Dicho sistema se encuentra actualmente instalado en la localidad de Huatacondo y su diagrama se puede observar en la Figura 3.

Las entradas a este sistema de gestión de demanda corresponden a:

- La estimación del estado de carga de las baterías (E_{SOC})

- Las predicciones de potencia solar y eólica, extraídas de los modelos de los generadores fotovoltaico y eólico respectivamente, los cuales se alimentan de predicciones climáticas para estimar la potencia.
- La predicción del consumo de agua y de consumo eléctrico, realizadas a partir de datos históricos.

Luego, como salidas del sistema de gestión se tienen:

- La referencia de potencia para el generador diésel (P_D)
- La potencia eólica y solar deseada (P_E, P_S)
- La potencia del inversor (P_I).
- Una señal binaria para la bomba de agua (B_P)
- La señal de gestión de demanda para los consumidores (S_L).

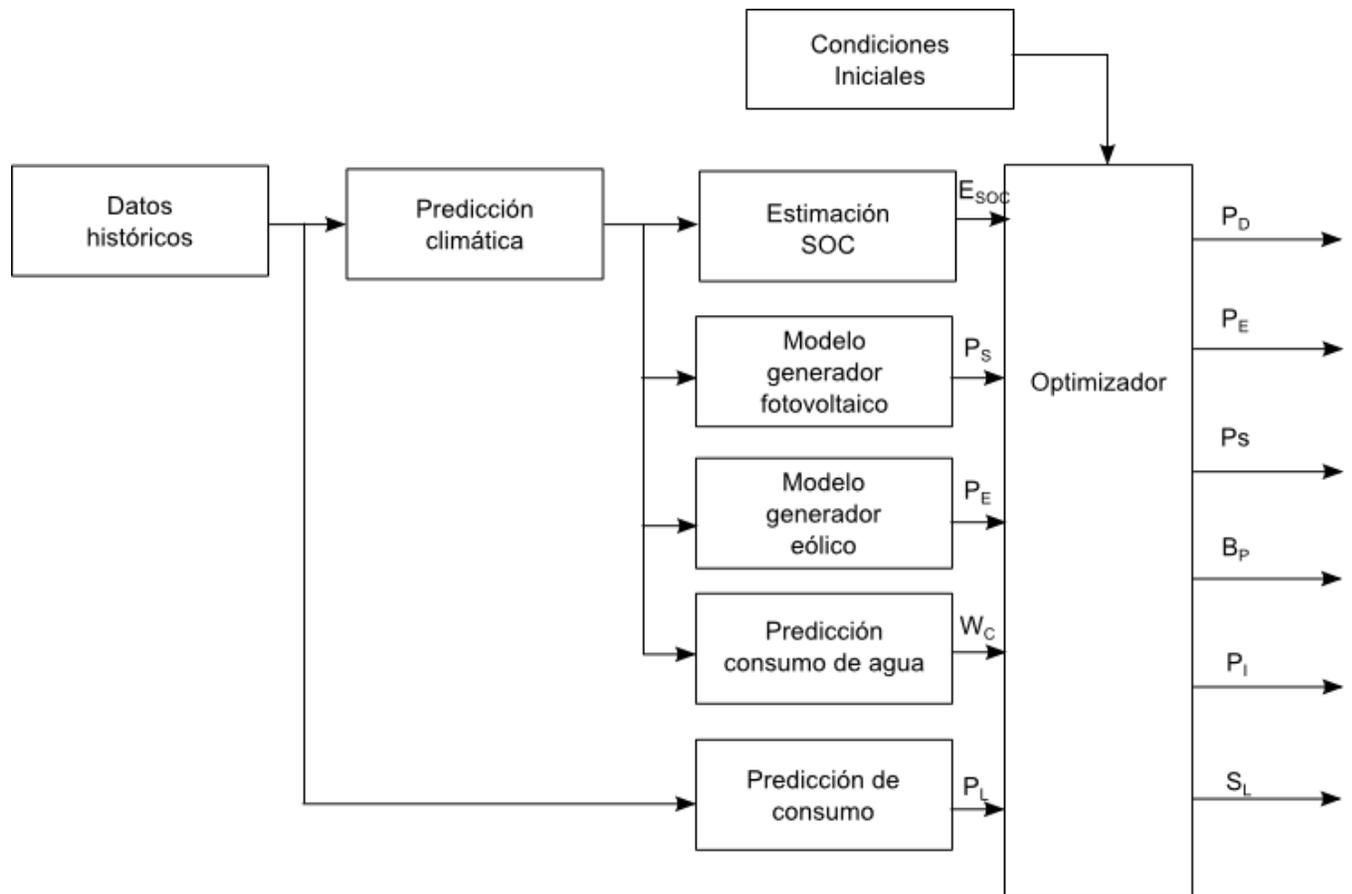


Figura 3: Diagrama del sistema de gestión de demanda instalado en Huatacondo

El EMS minimiza los costos de operación de la micro-red en un horizonte T determinado, utilizando pasos discretos de tiempo δ_t , es decir $t_{i+1} = t_i + \delta_t$. Así, la función objetivo que se desea minimizar es:

$$J = \delta_t \sum_{t=t_0}^T C(t) + \sum_{t=t_0}^T C_S(t) + C_{US} \delta_t \sum_{t=t_0}^T P_{US}(t) + C_{Tf} \sum_{t=t_0}^T V_{Tf}(t) + C_H(T) \quad 1$$

Donde $C(t)$ y $C_S(t)$ son las funciones de costo operación y de encendido del generador diésel respectivamente, $C_{US}(t)$ es el costo de la energía no servida, $V_{Tf}(t)$ el agua no servida, $C_{Tf}(t)$ el costo del agua no servida y $C_H(T)$ es el costo de utilizar el banco de baterías y afectar su vida útil. El problema del EMS es resuelto a un nivel supervisor en cada paso de tiempo, utilizando unit commitment con una estrategia de control predictivo. Se considera horizonte deslizante para la estrategia de control, para reducir el efecto de la incertidumbre asociada a las predicciones que se utilizan como entrada.

En micro-redes, para tener una operación segura, es de vital importancia mantener el balance entre la generación y la demanda. Por esta razón, uno de los temas tratados en esta tesis es el desarrollo de un módulo de predicción de demanda para micro-redes, utilizando como caso de estudio la micro-red de Huatacondo, al cual se le agregó además una etapa de análisis de estabilidad para que mantenga un comportamiento apropiado y no se indefina para casos específicos, afectando al sistema al entregar una predicción fallida.

Para el desarrollo tanto de la comunidad como de la micro-red, se presenta en [6] el sistema SCADA social implementado en Huatacondo, el cual es una herramienta computacional capaz de relacionar el ámbito eléctrico y el social, para así apoyar el desarrollo de la comunidad. Los indicadores que el sistema presenta a la comunidad, para que ésta pueda tomar decisiones, son:

- Monitoreo de las unidades de generación: Este indicador entrega información como el estado de las unidades (encendido/apagado) y potencia inyectada al sistema.
- Indicadores de sustentabilidad: Este indicador provee información como el ahorro de diésel y emisiones.
- Gestión del mantenimiento: Se entrega la agenda de mantenimiento y las tareas semanales.
- Consumo energético por casa: Al tener la información por casa se pueden tomar decisiones para apoyar desarrollo del pueblo en el contexto del ahorro de energía.
- Respuesta de la demanda: Entrega señales para modificar el consumo, lo que se detallará más adelante.
- Sistema de alarmas: Este indicador envía señales cuando se producen o pronostican fallas e indica la acción que se debe tomar para corregir el problema.

El sistema de gestión de energía incorpora un sistema de gestión de demanda basado en respuesta de la demanda, es decir, se envían señales a los consumidores para que estos modifiquen su consumo de manera de beneficiar a toda la micro-red. Con este sistema de gestión de demanda es posible compensar la fluctuación que presentan las fuentes de energía renovable no convencionales de manera de mantener el equilibrio sin la necesidad de aumentar la utilización del grupo electrógeno.

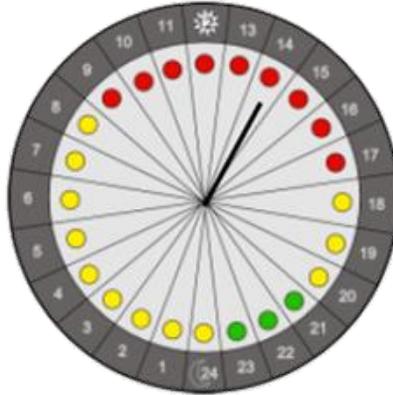


Figura 4: Semáforo para gestión de demanda

Las señales se envían mediante semáforos, como el de la Figura 4, instalado en las casas de los consumidores de la micro-red. El optimizador determina, para un horizonte determinado de tiempo, el color que tendrán dichas luces, dependiendo de las acciones que se requieran para que los consumidores tomen durante el transcurso del día. En la Tabla 2 se indica cuál es el comportamiento esperado de los consumidores, de acuerdo al color de la luz que se tenga en el semáforo para una hora dada. Es necesario remarcar el hecho de que no existen incentivos para los consumidores, mas que apoyar al sistema, ya que pagan un costo fijo no relacionado con su uso de la energía.

Tabla 2: Significado de las luces del semáforo

Color	Acción sobre el consumo
Rojo	Disminuir
Amarillo	Mantener
Verde	Aumentar

Se pretende que la demanda se desplace desde las horas con luz roja a las horas con luz verde, de acuerdo a un factor determinado por el optimizador del sistema de gestión de energía, denominado “factor de desplazamiento”. Por lo tanto, se espera que la potencia real sea:

$$\tilde{P}_L(t) = S_L(t)P_L(t) \quad (2)$$

Siendo $P_L(t)$ la potencia esperada de las predicciones y $S_L(t)$ el factor de desplazamiento óptimo que minimiza la función de costo de la micro-red. Debido a que este factor de desplazamiento depende de la respuesta de los consumidores, no es un valor exacto, por lo tanto, para tomar en

cuenta la máxima y mínima respuesta esperada de los consumidores a las señales, este factor de desplazamiento se encuentra acotado por el “rango de desplazamiento de carga”.

$$S_{L_{min}}(t) \leq S_L(t) \leq S_{L_{max}}(t) \quad (3)$$

Por lo tanto, si $S_{L_{min}}(t)$ es 0.9, entonces asume que el consumidor puede disminuir hasta un 10% su consumo en el periodo t , mientras que si $S_{L_{max}}(t)$ es 1.1, entonces se asume que el consumidor puede aumentar hasta en un 10% su consumo esperado. Estas cotas son dependientes del tiempo, ya que la disposición a modificar la demanda es diferente dependiendo del momento del día.

Por lo anterior, en esta tesis también se propone un método para la determinación del rango para el factor de desplazamiento, utilizando información histórica de demanda para predecir cómo ésta varía para cada intervalo de tiempo. Adicionalmente, se propondrá una estrategia para modelar el comportamiento de los consumidores ante las señales de gestión, para incorporar la variación a los resultados de la predicción de demanda.

3.3 Discusión

La presente tesis está basada en la micro-red instalada en la comunidad rural de Huatacondo. Esta micro-red que cuenta con un sistema de gestión de energía, está basada en energías renovables, principalmente del tipo solar y además fue diseñada de forma tal que la comunidad fuera parte activa del sistema, para apoyar el desarrollo social de esta localidad.

Debido a la incertidumbre inherente a las fuentes de energía renovable no convencionales, en este caso la energía solar, se necesitan medidas para lograr mantener el equilibrio entre generación y demanda. En Huatacondo se cuenta con un sistema de gestión de demanda del tipo respuesta de la demanda, mediante la cual los consumidores ajustan su consumo a las necesidades del sistema, aumentándolo o disminuyéndolo según las señales que observan en el semáforo de gestión de demanda. En cuanto a este tema, en esta tesis se plantean dos formas para mejorarlo, la primera consiste en utilizar intervalos difusos para determinar cuánto podría variar la demanda en el futuro, basado en las variaciones pasadas y también se planten una metodología para modelar la variación del consumo según las señales de gestión, utilizando modelación difusa de Mamdani.

Por otra parte, para mantener el equilibrio entre generación y demanda es necesario tener una buena predicción de esta última, por lo que se desarrollará un módulo de predicción de demanda basada en Takagi y Sugeno, a cuyo proceso de identificación se le adicionará una etapa de análisis de estabilidad para asegurar buen comportamiento.

4 Estado del arte

En el presente capítulo se presenta una revisión bibliográfica de los temas abordados en este trabajo. Se comienza por definir los conceptos de demanda eléctrica y micro-redes. Luego, se continúa con el concepto de gestión de demanda, los distintos tipos de gestión que existen y los trabajos que se han realizado sobre esto en el mundo, en distintos tipos de redes eléctricas, enfocándolo principalmente en la gestión de demanda en micro-redes. Finalmente, se trata la predicción de demanda eléctrica y las distintas técnicas que han sido utilizadas para abordar el tema en diversos contextos, tomando en cuenta especialmente micro-redes y redes con presencia de fuentes energéticas renovables no convencionales.

4.1 Demanda eléctrica y micro-redes

La demanda eléctrica juega un importante rol en la planificación de los sistemas eléctricos, ya que gracias a las predicciones de ésta se puede planificar la generación requerida para satisfacer un consumo previsto [7]. Ésta corresponde a la potencia presente en los terminales de un sistema promediada en un intervalo específico de tiempo. La generación instalada debe ser capaz de cumplir con la demanda máxima, la cual cambia durante el día y a lo largo del año [8], además se debe tener capacidad suficiente para hacer frente a incertezas en la generación y aumentos inesperados en la demanda.

En micro-redes, para tener una operación segura es de vital importancia mantener el balance entre la generación y la demanda. Este balance debe mantenerse en tiempo real, ya que las fluctuaciones de voltaje pueden causar serios daños a artefactos y en casos críticos se puede llegar a colapsos del sistema dejando a toda el área, cubierta por la micro-red, sin energía [9].

La demanda eléctrica se puede clasificar como industrial, comercial y residencial. Las demandas comercial y residencial varían estacionalmente, debido al uso de calentadores y aire acondicionado, la demanda industrial es mayormente estable durante el tiempo.

En cuanto a demanda, las comunidades rurales y los centros urbanos tienen características diferentes, en las primeras la mayoría viven de la agricultura o la ganadería, se tiene infraestructura deficiente y por lo general carencia de alumbrado público [10]. En las comunidades rurales, en donde las fuentes de energía eléctrica tradicionales son escasas, es importante mantener el equilibrio entre la generación y consumo, para lo cual se pueden utilizar técnicas de gestión de demanda.

A continuación se presentan técnicas utilizadas para realizar predicción de demanda, detallando más específicamente para corto plazo y micro-redes, ya que son las más cercanas al tema de tesis.

4.2 Predicción de demanda eléctrica

La predicción de demanda ha sido siempre un asunto importante en la planificación y operación de los sistemas eléctricos, tanto por las variables económicas como de seguridad [11]. La predicción de demanda se puede clasificar, según el horizonte de predicción, en las siguientes categorías [12]:

Largo plazo: Se utiliza para realizar predicción de 1 a 10 años. Es usada para identificar la necesidad de planificar e invertir en generación, dado que las grandes plantas de generación requieren de aproximadamente una década para estar disponibles, tomando en cuenta el diseño, financiamiento y construcción de estas instalaciones.

Mediano plazo: Para predicciones entre algunos meses y un año. Se utilizan para garantizar la seguridad y las restricciones de capacidad en el mediano plazo.

Corto plazo: Predicciones a un día, se utilizan para la planificación y para asistir a los participantes del mercado eléctrico.

Muy corto plazo: Son predicciones a horas o minutos, y se utilizan para asistir negociaciones o despachos eventuales.

Dependiendo del plazo de predicción, hay diversos factores que deben ser tomados en cuenta a la hora de realizar los modelos de predicción de demanda, como son el clima, el tiempo y la clasificación de los consumidores. El factor de tiempo incluye el mes, día de la semana y hora del día. El factor climático es uno de los más importantes para las predicciones a corto plazo, siendo la humedad y temperatura las variables más utilizadas.

Debido a que la mayor parte de las instalaciones eléctricas atienden a consumidores de diversos tipos, como residenciales, comerciales e industriales, el patrón de consumo es diferente para los distintas clasificaciones pero similar dentro de cada grupo [13].

A continuación se detalla la predicción de demanda a corto plazo, ya que es la adecuada al contexto de operación de micro-redes.

4.2.1 Predicción de demanda a corto plazo

La precisión de la predicción de demanda a corto plazo, depende principalmente de cinco factores [14]:

- La elección de la técnica adecuada de predicción, según el perfil de demanda.
- Utilizar el algoritmo apropiado, para estimar los parámetros del modelo de predicción.
- La inclusión de variables exógenas al modelo, que tengan alta correlación con la carga.

- La naturaleza del perfil de carga, como la varianza en los incrementos de la demanda.
- El horizonte de predicción.

A continuación se detallan las técnicas más utilizadas para realizar predicción de demanda.

Método de regresión

Este método, para la predicción de demanda, se utiliza mayormente para modelar la relación entre la carga y otros factores como clima, tipo de dato y tipo de consumidor. Haida y Muto [15] utilizan regresión para realizar predicción para el peak de carga diario. Para esto, consideran las estaciones del año, crecimiento anual de la carga y el último cambio diario en la carga. En [16], Engle et al. presenta modelos de regresión para predicción a un día. Estos modelos incorporan influencias determinísticas como feriados, influencias estocásticas como promedio de carga e influencias exógenas como el clima.

Series de tiempo

Este método se basa en que se asume que los datos tienen una estructura interna común, tal como autocorrelación, tendencia o variación temporal. Las series de tiempo más utilizadas son: ARMA (autoregressive moving average), ARIMA (autoregressive integrated moving average), ARMAX (autoregressive moving average with exogenous variables) y ARIMAX (autoregressive integrated moving average with exogenous variables). En [17] se utiliza ARIMA para realizar predicción de carga eléctrica, utilizando mínimos cuadrados para estimar los parámetros. En [18], Cho et al. se utiliza ARIMA y función de transferencia, para realizar predicciones de demanda a corto plazo, considerando una relación entre el clima y la demanda.

Aproximación por similitud entre días

Este método se basa en buscar información histórica de uno, dos o tres años con características similares al día que se quiere predecir. Estas características pueden ser el día de la semana, mes, estación del año o predicción meteorológica. En [19] se propone un sistema difuso para la predicción de demanda, basado en la aproximación por similitud entre días. Los días son elegidos utilizando norma Euclidiana, buscando similitud entre las variables climáticas. Y se utiliza inferencia difusa para corregir el pronóstico, tomando en cuenta las predicciones anteriores y los días elegidos como similares.

Redes neuronales

Las redes neuronales imitan el comportamiento de las neuronas biológicas, las cuales entrenándose con información conocida pueden inferir reglas internas y completar mapas matemáticos complejos [20]. La arquitectura más utilizada para la predicción de demanda es la de *backpropagation*, en la cual los pesos asignados a las neuronas se determinan al comparar los datos históricos con la salida de la red, en la etapa de entrenamiento.

Bashir et al [21] utiliza redes neuronales artificiales para realizar predicciones de demanda cada una hora, utilizando un algoritmo de optimización de enjambre de partículas (PSO: particle swarm optimization) para ajustar los pesos de la red en la fase de entrenamiento. Además, aplica transformada *wavelet* a los datos durante la fase de pre-procesamiento, para extraer la información redundante. Con el uso del enjambre de partículas y la transformada *wavelet*, se observa una mejora en comparación al modelo con red-neuronal que no incluye estas técnicas.

En [22] se utilizan redes neuronales para predecir peaks regionales de carga en Taiwan. Para entrenar la red se utiliza información que abarca desde 1981 a 1996 y para probar el modelo se utilizan datos históricos que van desde 1997 a 2000. El modelo utilizado se basa en *backpropagation* y la red consta de tres neuronas en la capa de entrada, dos neuronas en la única capa oculta y una neurona de salida. Los resultados de este modelo fueron comparados con el de un modelo de regresión creado con los mismos datos y se llegó a que el modelo con redes neuronales presenta un menor MAPE.

Lu [23] propone utilizar redes neuronales estructuradas para realizar predicción de demanda. En este tipo de red neuronal, grupos de neuronas de la capa escondida se conectan a cada neurona de entrada, no todas como pasa en las redes neuronales clásicas. Para realizar esta predicción se realiza una etapa de entrenamiento inicial para predicción de clima, carga y tipo de carga. Luego, se realiza un entrenamiento combinado utilizando el inicial, para tener finalmente la predicción de carga.

En [24] y [25] se utilizan redes neuronales para realizar predicción de demanda a una hora, tomando en cuenta como entradas variables climáticas como temperatura y humedad, siendo estas elegidas mediante análisis de correlación.

Sistema experto

Estos modelos utilizan reglas, principalmente de naturaleza heurística. Es decir, estos modelos incorporan reglas y procedimientos, usados por humanos expertos en la materia, en programas que logran realizar predicciones sin la asistencia humana. En [26] y [27] se utiliza esta técnica para realizar predicción de demanda a corto plazo. Utilizando el conocimiento histórico del comportamiento de la demanda e incorporando variables externas como el clima, se construyeron las reglas para lograr predecir la demanda.

Lógica difusa

La lógica difusa es una generalización de la lógica booleana usada para el diseño de circuitos digitales. Bajo la lógica booleana una variable toma un valor de verdad de “0” o “1”. Bajo la lógica difusa las variables están asociadas a rangos con ciertas cualidades, como puede ser “alto”, “bajo” y “mediano”. Este tipo de lógica permite tener grados de imprecisión en el razonamiento de manera que la información representada por términos como “alto”; “bajo”; “medio”, pueda ser procesada computacionalmente

En [28] se reevalúa la predicción de demanda utilizando un sistema basado en reglas difusas, representando los factores externos que influyen en la demanda, mejorando la predicción de demanda. Hinojosa et al [29] utiliza razonamiento difuso inductivo para realizar predicción de demanda eléctrica a corto plazo, con un horizonte de predicción de un día. En [30] se utiliza lógica difusa para realizar predicción de demanda, siendo las entradas la temperatura mínima y máxima del día, la época del año, capacidad del día, lluvia y nubosidad. El tipo de modelo difuso elegido para la predicción es Mamdani, el cual relaciona todas las entradas listadas, obteniéndose un error porcentual bajo el 5% en las predicciones realizadas.

Máquina de soporte de vectores

La máquina de soporte de vectores corresponde a una técnica para resolver problemas de clasificación y regresión. Esta técnica realiza un mapeo no-lineal (utilizando funciones llamadas kernel) de los datos sobre un espacio de alta dimensión.

En [31] Xu et al. utilizan esta técnica para realizar predicciones de demanda diarias, para lo cual utiliza datos históricos de demanda por hora, siendo la salida la demanda para las próximas 24 horas. En [32] se realiza una partición geográfica óptima, tomando en cuenta el clima, y se realiza la predicción de demanda en cada área por separado, utilizando para esto la máquina de soporte de vectores, finalmente se unen estas predicciones para obtener la predicción del área total.

También se han propuesto trabajos, en los cuales se mezclan las técnicas presentadas para realizar predicción de demanda. En [33] se realiza la predicción de demanda a una hora, utilizando redes neuronales y la técnica de similitud de días. En [34] se utiliza una red neuronal basada en los modelos difuso de Takagi y Sugeno (ANFIS: Adaptive neuro-fuzzy inference system) para realizar las predicciones de demanda eléctrica, con un horizonte de predicción de un día. Una de las entradas de este modelo es la temperatura máxima predicha para el día siguiente y la demanda del mismo día en el año anterior.

En [35] se proponen y evalúan tres técnicas para predicción de carga a corto plazo. Estas son: lógica difusa, redes neuronales y modelos autoregresivos. En dicho trabajo se concluye que el desempeño de los modelos de predicción de carga, basados en lógica difusa y redes neuronales es superior al modelo autoregresivo.

El trabajo desarrollado en esta tesis se encuentra en el contexto de micro-redes, por lo tanto, en la siguiente sección se presentan trabajos realizados específicamente sobre predicción de demanda para micro-redes.

4.2.2 Predicción de demanda en micro-redes

Dado el tamaño reducido de las micro-redes, cualquier cambio en el uso de la electricidad puede tener un impacto significativo en la carga de la micro-red, por lo cual es más compleja la predicción de demanda. Esta predicción a corto plazo sirve como guía para una correcta programación de despacho de las unidades de generación y gestión de la micro-red [36].

En [37], Amjady y Keynia proponen una estructura de dos niveles para realizar predicción de demanda eléctrica en micro-redes a corto plazo. En la Figura 5 se observa la estructura de predicción propuesta. El nivel inferior incluye un método para la selección de variables y un motor de predicción híbrido. El primer paso, en este nivel, es identificar los factores que afectan a la carga eléctrica, a través del método para la selección de variables. La fase de selección de variables, se basa en un método desarrollado por los mismos autores previamente en [38]. Este método filtra las variables que son irrelevantes y redundantes, para que queden solo las variables que aporten a la predicción. Para elegir que variables son irrelevantes y redundantes se definen dos umbrales: el umbral del filtro de irrelevancia “ $TH1$ ” y el umbral del filtro de redundancia “ $TH2$ ”, los cuales son parámetros ajustables.

La segunda componente del nivel inferior es el motor de predicción híbrido, que tiene como entrada las variables ya filtradas. El motor de predicción propuesto por los autores, esta vez en [39], está compuesto por redes neuronales y algoritmos evolutivos, teniendo así dos parámetros ajustables, el número de nodos ocultos de la red neuronal (N_H) y la constante de momentum del algoritmo evolutivo (m). Se asume que la red neuronal tiene sólo una capa oculta.

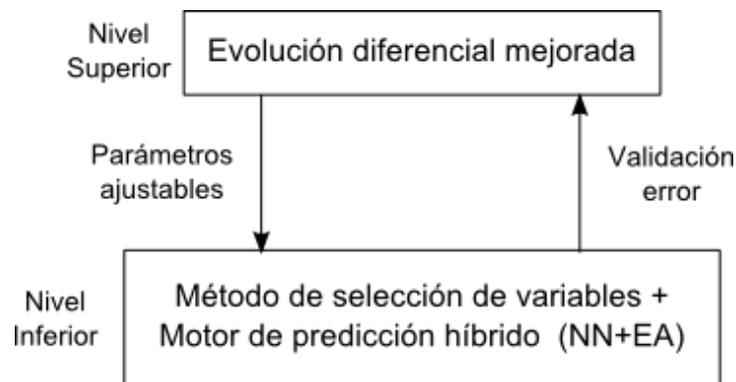


Figura 5: Estructura de la estrategia de dos niveles para predicción de carga a corto plazo [37]

El nivel superior se encarga de optimizar el desempeño del predictor de carga, utilizando evolución diferencial mejorada (EDE). La evolución diferencial (DE), es una estrategia de búsqueda estocástica que se basa en la población actual para guiar el proceso de búsqueda, desarrollada por Storn y Price [40]. Para optimizar el rendimiento del predictor, Amjady y Keynia proponen una versión mejorada de la estrategia de evolución diferenciada, obteniendo una estrategia que tiene mayor convergencia y evita que el proceso de búsqueda del óptimo quede atrapado en mínimos locales.

Uniendo los dos niveles, se tiene que los individuos del EDE corresponden a los cuatro parámetros ajustables del nivel inferior, es decir: $TH1$, $TH2$, N_H y m . Finalmente, el error de validación de la red neuronal, corresponde a la función objetivo del EDE, el cual se minimiza, con lo que se tiene la estructura de dos niveles para la predicción de carga eléctrica.

Chan et al [41] utiliza un sistema clasificador múltiple, combinado con redes neuronales, para realizar predicciones de demanda a corto plazo en micro-redes inteligentes. El modelo, expuesto

en la Figura 6, consta de cuatro clasificadores base. Para estos clasificadores se utilizan redes neuronales, ya que tienen una buena capacidad de generalización. Los datos utilizados, correspondientes a información pasada de carga, son divididos en cuatro partes: 24 horas, 3 días, 1 semana y 1 mes antes de la hora de predicción. Estos conjuntos, representan el conocimiento que se tiene para diferentes periodos de tiempo y diversifican el conocimiento del clasificador. Con estos conjuntos de datos se entrenan los cuatro clasificadores para luego probar la predicción de cada uno y de acuerdo a su desempeño, se le asigna un peso a cada clasificador base, lo que corresponde a la etapa de peso dinámico. Finalmente, de acuerdo a los pesos, se fusiona la información de los clasificadores obteniéndose una predicción final.

La metodología propuesta por Chan et al, fue evaluada utilizando datos reales de carga, de Hong Kong. Los factores seleccionados como entradas son: tiempo, temperatura del punto de rocío, humedad, presión a nivel del mar, velocidad del viento y si se trata de día de semana o fin de semana. Este método se compara con la utilización de Wavelets Neural Network (WNN) para realizar predicción de demanda, utilizando el índice MAPE como medio de comparación. Como resultado se obtiene que la metodología de predicción propuesta tiene un MAPE menor en un 1,01% al obtenido al utilizar WNN.

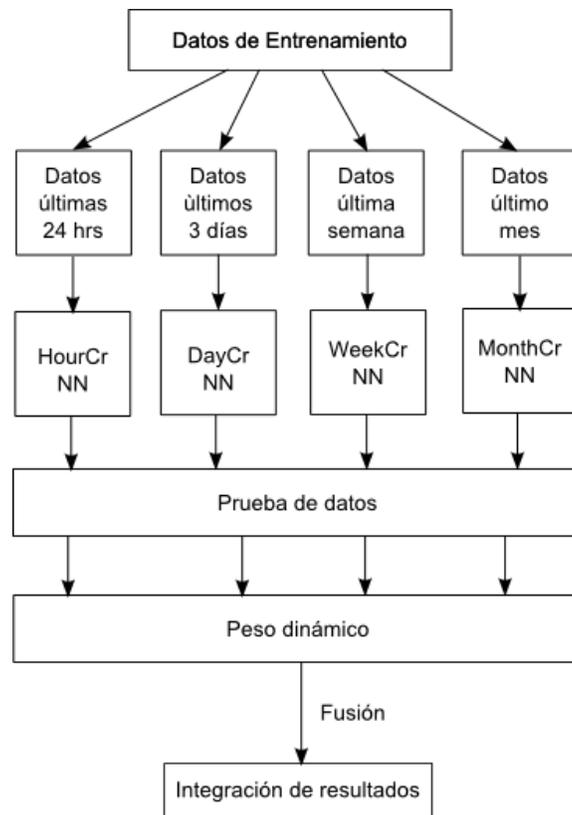


Figura 6: Arquitectura del método de clasificador múltiple [41]

4.2.3 Discusión

La predicción de demanda es un factor importante en la gestión de sistemas eléctricos, ya que permite una correcta programación de despacho de unidades en el corto plazo y ayuda en la planificación de inversiones en generación y distribución cuando se utiliza a largo plazo. Por esta razón, existen diversas técnicas para la predicción de demanda.

En micro-redes basadas en energías renovables, tener una predicción de demanda correcta es aún más crítico, debido a que cualquier cambio en el uso de la electricidad puede tener un impacto significativo en la operación de la micro-red, y además se debe considerar el comportamiento fluctuante de las fuentes de energía renovables. Para este caso específico, las técnicas utilizadas constan de varias etapas, dentro de las cuales generalmente se incluyen redes neuronales, debido al comportamiento no lineal de la demanda.

Otra técnica utilizada para mantener el equilibrio entre generación y demanda, es la gestión de demanda, la que también sirve para evitar peaks de demanda y disminuir el uso de fuentes de energía contaminante al aprovechar de mejor manera los recursos renovables, mediante de cambios realizados en el lado de la demanda. En la siguiente sección se exponen los distintos tipos de gestión de demanda que existen y los más utilizados para gestión en micro-redes.

4.3 Gestión de demanda

El concepto de gestión de demanda (DSM : Demand Side Management) fue introducido en 1980 por el *Electric Power Research Institute* y se definió como una serie de actividades realizadas por el gobierno y las empresas públicas para aumentar el beneficio social y disminuir la necesidad de invertir en la industria eléctrica [42].

El objetivo principal de los programas de DSM es aumentar la eficiencia energética en el lado de la demanda, lo que beneficia tanto a consumidores como a generadores. Un DSM inteligente debiese aspirar a realizar una interacción efectiva entre la red y el usuario para mejorar el servicio y apoyar el acceso a las energías verdes. En general los programas de DSM están diseñados, como se observa en el gráfico de la Figura 7, para [43]:

- **Reducir peaks de demanda:** Esto es aplicable cuando se tienen problemas de capacidad durante periodos cortos de tiempo, como por ejemplo en una tarde calurosa en donde se encienden múltiples máquinas de aire acondicionado o en mañanas frías en donde las industrias están encendiendo las maquinarias y además necesitan calefacción al mismo tiempo.
- **Rellenar los valles de la curva de demanda:** Esto se utiliza en periodos largos donde la demanda es notoriamente menor que la generación por lo que se están perdiendo recursos.

- **Lograr un aumento estratégico de la carga:** Esto se aplica cuando existe un gran exceso de capacidad de generación inutilizada.
- **Mover carga:** Cuando existen problemas de peak de demanda de manera regular y las cargas de los clientes se pueden mover dentro del día, como cambiar los patrones de producción en la industria.
- **Flexibilizar Carga:** El uso de energía con altos índices de fluctuación, como la proveniente de turbinas eólicas o paneles fotovoltaicos, resulta en que las plantas térmicas sean afectadas por cambios en las cargas de manera más frecuente, esto se puede contrarrestar flexibilizando las cargas en función de la generación intermitente.

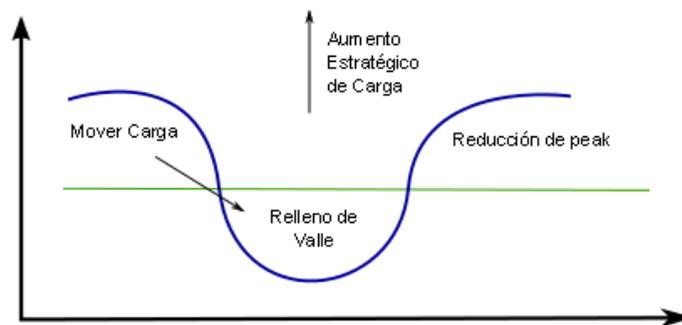


Figura 7: Áreas de la curva de carga que pueden ser modificadas [43]

En [44] se propone que para tener un buen diseño de DSM se deben tener los siguientes puntos en cuenta:

- Interacción entre la red y los usuarios.
- Mejorar le eficiencia energética.
- Proveer información comprensiva.
- La información de los equipos eléctricos debe estar disponible para el diseño.
- Debe ser útil para resolver problemas medioambientales (reducción de emisiones).

En las siguientes secciones se presentan técnicas de gestión de demanda, primero para sistemas eléctricos en general, detallando las principales técnicas que se utilizan para implementar estos programas. Luego, se especifican técnicas de gestión de demanda aplicadas concretamente a micro-redes basadas en energías renovables y los resultados que se han obtenido en diversos países.

4.3.1 Técnicas de gestión de demanda

Los programas de gestión de demanda son empleados para proveer de mayor capacidad al sistema sin la necesidad de nuevas instalaciones de generación. Éstos incluyen programas de: conservación y eficiencia energética, los cuales se enfocan en la utilización de artefactos

eléctricos eficientes, como ampolletas de bajo consumo, y realizar prácticas de ahorro como apagar la luz en habitaciones desocupadas y evitar el “consumo vampiro” al desconectar artefactos que se encuentren apagados; sustitución de combustibles; respuesta de la demanda y control de carga [45]. A continuación se detallan estos dos últimos tipos de programas de gestión de demanda.

Control de carga

Estos programas están diseñados para reducir los peaks de demanda o cambiar bloques de demanda desde periodos con peak a periodos sin peak, realizando acciones sobre las cargas que se encuentran conectadas a la red. Entre estos programas se encuentran los de control directo de carga y los de cargas interrumpibles.

Control directo de carga

Esta técnica consiste en tener ciertas cargas cuyo funcionamiento sea controlado completamente por el sistema encargado de la distribución energética [46], para lo cual primero se deben identificar las que pueden participar. En el área doméstica se pueden considerar los artefactos refrigerantes, además de artefactos de calefacción como cargas que pueden participar de la demanda dinámica como “*responsive loads*” [47].

En [48] se estudian los cambios generados en la curva de carga en el sector residencial, al utilizar el control directo de carga, para lo cual se modelan las cargas para anticipar los efectos del control desde el punto de vista de las modificaciones a la curva de carga y de las expectativas de los usuarios, las cuales no se toman generalmente en consideración, como por ejemplo tener un nivel cómodo de temperatura durante y después de la acción de control, si ésta se realizara al aire acondicionado. Se aplicaron las acciones de control a artefactos HVAC (heating, ventilation and air conditioning), tomando en cuenta una predicción de la evolución de la demanda y temperatura interior bajo la acción de control, obteniéndose una reducción del 5% en los peaks, como se muestra en la Figura 8.

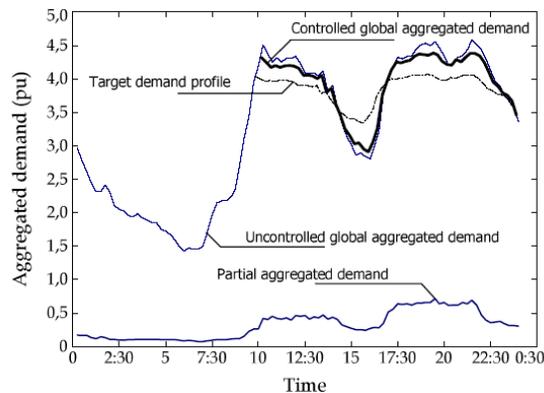


Figura 8: Control directo de carga aplicado en artefactos HVAC [48]

Cargas interrumpibles

Las cargas interrumpibles corresponden a consumidores que están dispuestos a interrupciones de servicio, bajo ciertas restricciones, siendo recompensados con tarifas reducidas. Estos consumidores por lo general corresponden a grandes industrias que poseen su propia generación de respaldo o que pueden reprogramar su producción de manera sencilla [45].

Respuesta de la Demanda

Los programas de respuesta de la demanda (DR: Demand Response) consisten en realizar cambios a corto plazo en los patrones de demanda eléctrica de los consumidores, para reducir o desplazar la carga en el tiempo [49]. Estos programas suelen estar basados en incentivos monetarios, en donde los consumidores reciben pagos o tarifas preferenciales por reducir su consumo en periodos de estrés del sistema, o basados en tarifas temporales, en donde los consumidores reducen su demanda respondiendo a señales de precios.

Generalmente estos programas se ven como oportunidades económicas, en [50] se identifican como beneficios de este tipo de gestión de demanda la reducción de los precios de la electricidad, la mejora en el nivel de confiabilidad del sistema y la reducción de la volatilidad en los precios. En el trabajo realizado en [51] se desarrolla un algoritmo denominado CAES (Consumer Automated Energy Management System), el cual agenda el consumo eléctrico de los consumidores, quienes realizan “reservas de energía” al decidir que artefactos utilizarán mediante acciones como apretar un botón de encendido. La acción del CAES repercute estadísticamente en la relación entre los futuros precios y los artefactos seleccionados por los consumidores. Las simulaciones demostraron que el algoritmo permite una reducción en costos de hasta un 40% para el consumidor, con respecto a un sistema en el que no se agenda el uso de la energía.

También la respuesta de la demanda se utiliza, como en [52], para realizar regulación de frecuencia y voltaje. En este caso se trabaja con un generador diésel y cargas resistivas e inductivas, de las cuales solo las primeras son controladas. La acción de control consiste en apagar parte de las cargas resistivas cuando la diferencia de frecuencia es negativa (debido a la baja generación o alta demanda) y encender parte de las cargas en caso contrario. Las simulaciones realizadas muestran que este tipo de gestión de demanda es útil para el control de frecuencia y voltaje para micro-redes aisladas.

Entre los programas basados en incentivos se encuentran los de Ofertas de Demanda y dentro de los basados en tarifas temporales se encuentran los de tarifa por tiempo de uso, los cuales se detallan a continuación

Ofertas de Demanda

Estos programas están disponibles para consumidores que están dispuestos a disminuir su demanda por un determinado precio. Varios de estos programas utilizan internet, medio por el

cual el consumidor obtiene información de los precios y puede tomar decisiones para administrar su demanda de acuerdo a las ofertas del mercado [53].

En [54] se presenta una arquitectura basada en agentes para realizar transacciones y gestionar energía en micro-redes. Las transacciones se realizan con consumidores que aceptan participar en el programa de “respuesta de la demanda”, dando permiso a que el sistema de la micro-red opere sus artefactos electrónicos cuando el costo de la electricidad es bajo.

Tarifa por Tiempo de Uso (ToU)

Esta técnica es considerada una de las más importantes en cuanto a gestión de demanda. El enfoque tradicional consiste en persuadir a grandes consumidores industriales a mover sus cargas durante el día, utilizando distintos bloques de tarifas como incentivo. Estas tarifas están relacionadas con los peaks de potencia, siendo más económicos los bloques horarios en que se tiene menos consumo y más caros los con mayor consumo [55]. En [56], considerando la importancia de esta técnica para reducir los peaks de consumo y para la conservación de energía, se proponen métodos para enseñar a los consumidores a beneficiarse de esta técnica desde una temprana edad, tomando en cuenta que utilizar un secador de pelo media hora antes de lo usual o cambiar el horario para el lavado de ropa, puede traer consigo considerables beneficios.

A continuación se detallan programas de gestión de demanda aplicados en micro-redes que utilizan unidades de generación con energías renovables.

4.3.2 Gestión de demanda en micro-redes

El aumento de los precios de la energía fósil y una mayor conciencia medioambiental han impulsado el desarrollo de energías renovables y centrales de generación distribuida. El concepto de generación distribuida corresponde a plantas instaladas de manera dispersa, normalmente cerca de los consumos, lo que permite una disminución de las pérdidas y la posibilidad de aprovechar los recursos energéticos locales [57]. La gestión de la demanda, en este contexto, es una herramienta poderosa que permite una utilización más efectiva de la red sin la necesidad de nuevas inversiones en transmisión y centrales térmicas de reserva de energía. [58].

La generación distribuida abarca un amplio rango de tecnologías de generación de energía, como motores de combustión interna, turbinas a gas, micro-turbinas, paneles fotovoltaicos, celdas de combustible y energía eólica. Las micro-redes permiten una alta penetración de la generación distribuida sin que se requiera rediseñar el sistema de distribución [59]. El concepto de micro-red asume la integración de cargas y micro-fuentes operando como un sólo sistema proveyendo energía y calefacción [60].

En [59] se distinguen dos principios fundamentales que impulsan el concepto de micro-redes. El primero es que se necesita una perspectiva de sistema para que los consumidores puedan obtener todos los beneficios de integrar generación distribuida al sistema de energía; el segundo es que

para acelerar la adopción de este tipo de generación se necesita, principalmente, reducir los costos y aumentar el valor de las micro-redes.

En conjunto, el control local de generación y de carga es el corazón del concepto de micro-redes, lo que da un particular significado a la gestión de demanda. Más que un control de la carga con el propósito de ajustar su perfil para beneficiar a todo el sistema de potencia, el control de generación y carga de las micro-redes tiene como meta alcanzar la demanda de los consumidores de la manera más económica posible [60].

Las micro-redes basadas en energías renovables se pueden entender como un caso de redes inteligentes, el que corresponde a un conjunto de soluciones tecnológicas para el manejo de sistemas de potencia. Mediante el uso de protocolos de internet en dispositivos del hogar, la red inteligente es capaz de intercambiar información entre los consumidores y los centros de generación distribuida, lo que permite una participación informada de los consumidores [61]. La puesta en marcha de nuevas infraestructuras para las tecnologías de información y comunicación, asociadas a las redes inteligentes, representan una oportunidad para las soluciones de gestión de demanda, ya que facilitará la comunicación con los usuarios para mantener el balance entre la generación y la demanda, lo cual supone un reto en las micro-redes basadas en este tipo de energía, por las fluctuaciones asociadas a las fuentes de energías renovables no convencionales. Además, se da la posibilidad de realizar control directo de carga en artefactos inteligentes, que pueden ser apagados o encendidos de manera remota para poder adelantar o retrasar su funcionamiento [62].

Como se mencionó anteriormente, es de suma importancia mantener el equilibrio entre generación y demanda para mantener una operación segura de la micro-red, de modo de prevenir cortes de energía, que pueden darse cuando la capacidad de generación y energía almacenada, es superada por la demanda. Una solución para esto es el control directo de carga, que consistirá en este caso en desconectar cargas cuyo funcionamiento no sea esencial [63]. En [64] se propone un sistema en donde un controlador central se comunica directamente con las cargas, pudiendo ordenar su desconexión de la micro-red y así logrando disminuir la demanda total para mantener un balance energético, especialmente durante horarios peak. La mayor dificultad de este método consiste en identificar que cargas pueden ser o no desconectadas. Este problema es abordado en [65] donde tomando en cuenta atributos como: peak de consumo; horario de funcionamiento y forma de operación (como ciclos de trabajo en el caso de artefactos con termostato), se pueden identificar las cargas a partir de los datos de consumo medidos, para que así se les pueda asignar prioridad de modo de desconectar las cargas desde la menos importante. Luego, este controlador central (MGCC), cuya arquitectura se encuentra en la Figura 9, es capaz de comunicarse directamente con las cargas pudiendo aislar las con menor prioridad, reconociéndolas al observar el perfil de consumo.

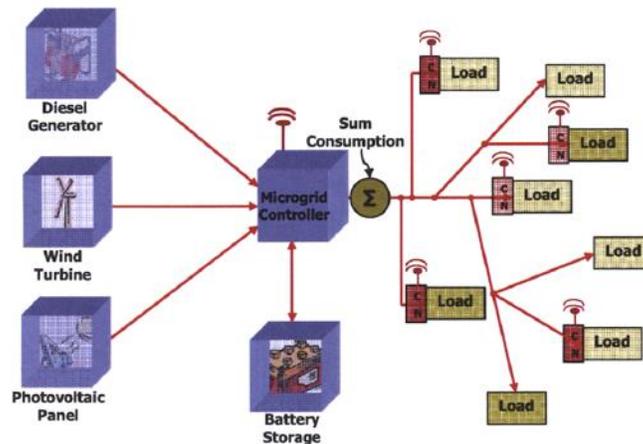


Figura 9: Arquitectura MGCC [64]

En la actualidad existe una directiva europea que ha promovido fuertemente la construcción de edificios con consumo casi nulo de energía (NZEB: Nearly zero energy buildings), los cuales son altamente eficientes en materia de energía y la pequeña cantidad de energía que necesitan puede ser cubierta por fuentes de energía renovables, incluyendo cogeneración o CHP (combined heat and power). En [66] se presenta como caso de estudio una micro-red para un NZEB, para la cual se sugiere la utilización de un sistema de control y automatización (BACS : Building Automation and Control System) para medir el consumo, controlar la generación y realizar acciones de gestión de demanda mediante el control directo de carga.

El edificio considerado consiste de 70 unidades del tipo residencial u oficina, áreas comunes, estacionamiento, jardines, etc. Cada unidad individual consume aproximadamente 300MWh/año y el sistema de calefacción 400MWh/año. El sistema cuenta además con un sistema CHP que consiste en una microturbina a gas natural Turbec T100, la cual puede suministrar 100kW de potencia eléctrica y 167 kW de potencia térmica con una eficiencia de 78%.

Un punto importante para controlar el NZEB es diseñar una estrategia de control de carga que actúe a nivel del BACS, tomando en cuenta que las cargas utilizadas en los hogares tienen distinto grado de posibilidad de ser controladas, es necesario caracterizarlas. Como primer paso se caracterizaron los hogares, para estimar sus perfiles de carga, las unidades se subdividieron en tres categorías:

- Económica.
- Estándar, con aire acondicionado en una habitación y más energía para iluminación y lavadora.
- Lujosa, con aire acondicionado en todas las habitaciones y más energía para iluminación, lavadora y secadora.

Para todas las unidades se consideraron calderas eléctricas para el agua caliente. Luego, las cargas fueron separadas en; No controlables (cargas que no es posible controlar, principalmente

porque dependen de los hábitos de los ocupantes de la unidad), planeables (cargas para las cuales se puede escoger el momento de inicio) y controlables (cargas a las cuales se puede retrasar el tiempo de inicio y además se pueden encender o apagar sin perjuicio de los consumidores, como la caldera eléctrica del edificio). Cada carga es activada como consecuencia de la acción de los consumidores, en un escenario no controlado el perfil agregado de carga dependería del perfil de carga de cada artefacto y el momento en que se requiere su uso. En el caso presentado en [66], cada vez que un consumidor pide la iniciación de alguno de los artefactos de su hogar o que comience el ciclo de calefacción, se inicia un requerimiento en el BACS, el cual resuelve un problema de optimización. La salida corresponde a un retraso en el tiempo de inicio para el artefacto requerido (15 minutos máximo para cargas cuyo uso es mas crítico como artefactos de cocina y 5 horas máximo para cargas menos críticas como lavadoras), dependiendo de los otros artefactos que se encuentren en espera de también ser encendidos y del tipo de carga de que se trate.

En la Figura 10 se muestra una comparación entre el sistema con y sin control. El seguimiento de una referencia de carga, determinada a partir de los perfiles construidos, tomando en cuenta el consumo promedio del edificio y las cargas no controlables, permite un perfil más regular en el caso controlado, con menos peaks y valles.

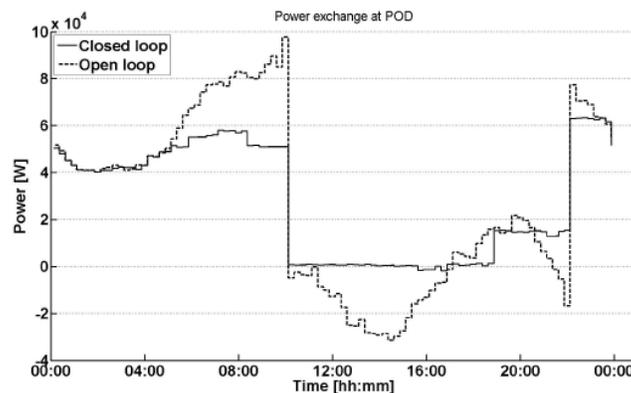


Figura 10: Balance de carga [66]

En [67] se propone realizar gestión de demanda tomando en cuenta restricciones de privacidad, realizando un intercambio parcial de información entre el sistema y los consumidores. Para esto se trabajó con una micro-red que consiste en varias células unidas por un centro de control. Cada célula consiste en un medidor inteligente, una fuente de generación distribuida y algunos consumidores. Además, la micro-red está conectada a un gran sistema de distribución principal que cuenta con generadores tradicionales. El problema se resuelve como un problema de optimización lineal que tiene como objetivo minimizar la utilización de la energía desde el gran sistema de distribución al que se encuentra conectado la micro-red, ya que los generadores de ésta producen contaminantes. Las cargas de los consumidores se dividen en no-programables y programables, éstas últimas son las que presentan problemas de privacidad ya que significan dar información del comportamiento de los consumidores, por lo tanto esta información es deseable que no se conozca ni por el centro de control ni por las otras células.

En dicho trabajo se trata el problema de optimización utilizando descomposición dual, luego se realizan simulaciones considerando una micro-red con 4 células. La resolución propuesta se comparó con dos casos, el primero asumiendo que ninguna de las cargas es programable (ETS-only: energy transmission scheduling only) y un caso en el que cada célula optimiza por separado sus cargas programables (DS-only: demand scheduling only). En la Figura 11 se observa el rendimiento para las estrategias simuladas, en cuanto a la importación de energía desde la red principal a la micro-red. Se obtuvo mejor comportamiento, es decir, un menor traspaso de energía, para el caso propuesto ya que a diferencia de los casos ETS y DS, este considera interacción entre las células para realizar la programación de demanda.

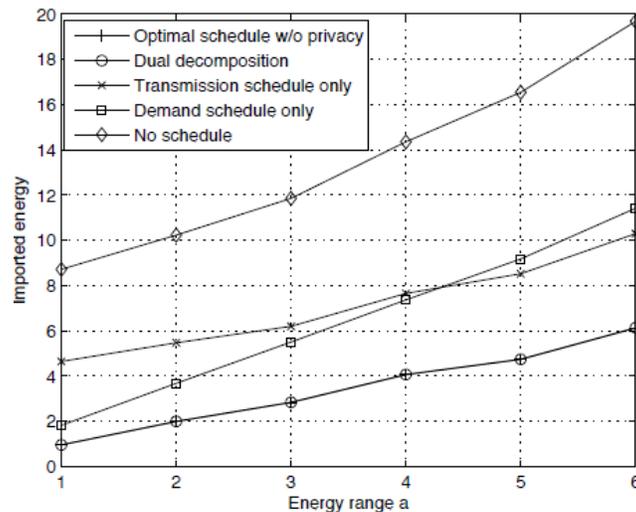


Figura 11: Comparación entre el rendimiento de los distintos tipos de programación de demanda

Uno de los principales problemas de las micro-redes que incorporan energía eólica, es la intermitencia en la generación. Esto lleva a que se deban tomar medidas para poder mantener un equilibrio entre la demanda y la generación ante una posible disminución repentina de ésta, como por ejemplo mantener unidades térmicas en *standby*. En general los sistemas de gestión de demanda modifican la demanda para reducir los peaks o el consumo, pero no mitigan los problemas de intermitencia [68].

En [68] se comprueba que al utilizar gestión de demanda dinámica en una red con alta penetración de energía eólica (10%) se pueden mejorar diversos indicadores. La gestión de demanda dinámica corresponde a utilizar técnicas de control directo de carga que se activan según los niveles de generación, en este caso eólica. Para esto utilizan el sistema “IEEE Estándar 30 Bus Test”¹ agregando dos granjas eólicas de 15MW y 20MW. Se tomaron como cargas

¹http://www.ee.washington.edu/research/pstca/pf30/pg_tca30bus.htm

controlables todas las cargas del área doméstica, las cuales respondían ante los cambios en el viento de la siguiente manera:

Si Energía Eólica < 10MW entonces reducir la demanda un 5%

Si Energía Eólica < 5MW entonces reducir la demanda un 10%

Cuando la demanda disminuye como respuesta a una disminución del viento, entonces se minimiza la necesidad de unidades a gas. Lo que como puede observarse en Figura 12, se traduce en una reducción de los costos totales, además de la reducción de emisiones, ver Figura 13, asociadas a las plantas tradicionales.

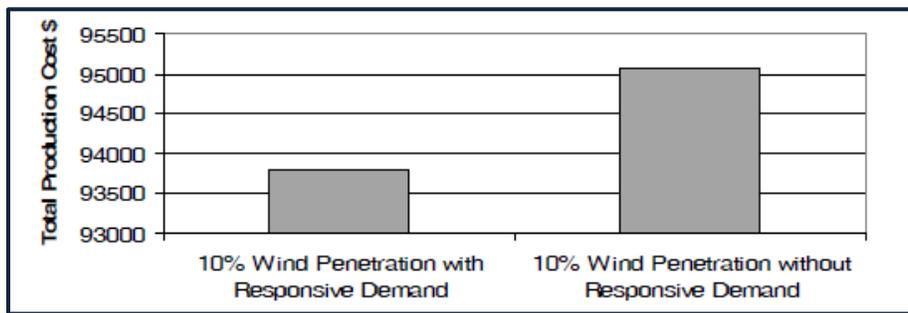


Figura 12: Costo de Producción Total [68]

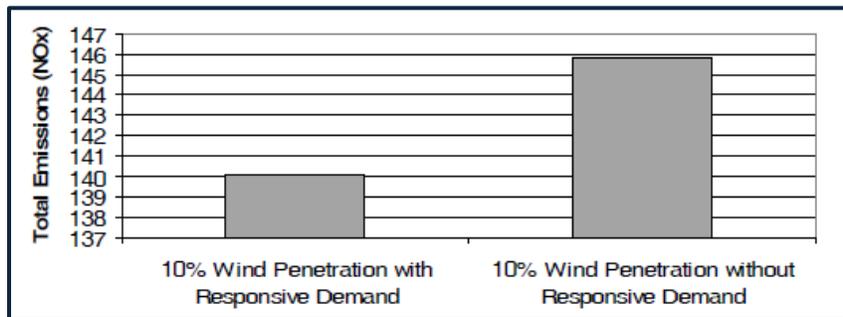


Figura 13: Emisiones Totales [68]

Por otra parte, en [69] se propone un sistema de gestión de demanda que aborda la intermitencia de la energía eólica en una micro-red aislada, utilizando teoría de juegos y modelando a los consumidores como tomadores de decisiones independientes. Se considera una micro-red aislada con N usuarios que comparten la energía generada por dos tipos de generadores, un generador diesel de respuesta rápida y una turbina eólica. El periodo en donde se realiza la gestión de demanda se divide en H partes, dependientes de la frecuencia con la que se mide la velocidad del viento. Se asume que cada consumidor tiene una carga controlable, la cual debe ser utilizada en un periodo determinado de tiempo que comienza en α_n y termina en β_n , por lo tanto, siendo x_n^h la

carga del usuario n durante el espacio h de tiempo y E_n el total de energía consumida por la carga del usuario n , se tiene:

$$\sum_{h=\alpha_n}^{\beta_n} x_n^h = E_n \quad (4)$$

$$\begin{cases} x_n^h \geq 0 \\ x_n^h = 0 \end{cases} \quad \alpha_n \leq h \leq \beta_n \quad \forall n \quad (5)$$

El costo total de la generación es compartido por todos los usuarios en proporción a su consumo personal. Cada usuario independientemente, basándose en las predicciones de energía eólica, decide sobre su consumo al inicio de cada espacio de tiempo para maximizar su rentabilidad, luego el costo real de electricidad se hace al final de cada espacio de tiempo considerando la cantidad real de energía eólica generada. La simulación se llevó a cabo considerando un horizonte de 24 horas, 50 usuarios y predicciones de generación eólica utilizando cadena de Markov. Se compararon tres casos; el primero sin utilizar DSM; el segundo utilizando DSM y cadena de Markov para predecir la generación eólica y finalmente utilizando DSM y una predicción perfecta de la generación eólica. Considerando equilibrio de Nash, en donde cada consumidor está ejecutando su mejor estrategia dadas las estrategias de los demás usuarios, utilizando DSM se logra una reducción de un 38% en los costos de generación, como se observa en la Figura 14.

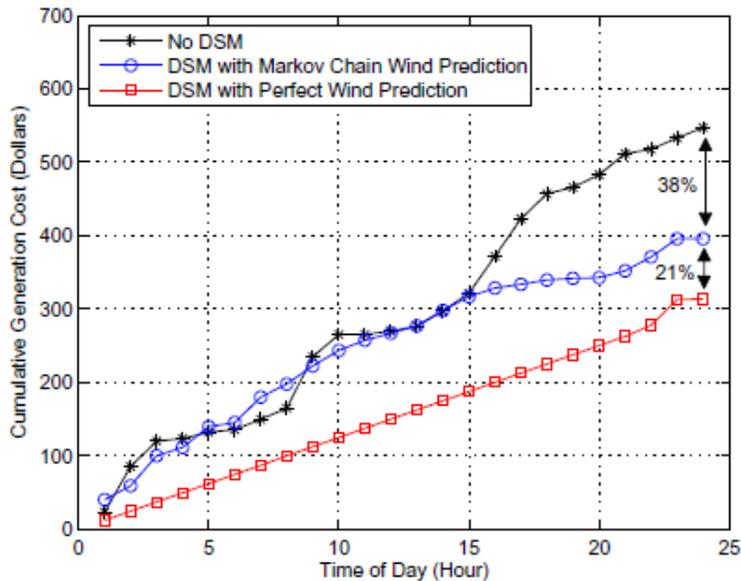


Figura 14: Costo de generación en un horizonte de 24 horas [69]

Otro caso es el estudiado en [70], aquí se considera una micro-red inteligente con alta penetración de energía eólica, en la cual los hogares cuentan con medidores. Los hogares actúan como agentes, dando prioridad a sus tareas, las cuales corresponden al uso de artefactos eléctricos en

distintos horarios. El trabajo propuesto utiliza respuesta de la demanda dinámica para elegir que tareas son llevadas a cabo, de manera de beneficiar al sistema sin desfavorecer a los consumidores. De las simulaciones realizadas se concluye que este tipo técnica de gestión de demanda es efectiva en cuanto a reducción de costos de generación.

Por otra parte, en [71] se supone el envío de señales a los consumidores para realizar la gestión de la demanda en una micro-red inteligente instalada en Huatacondo, los despachos de ésta red están realizados por un EMS (*Energy Management System*) el cual toma en cuenta predicciones climáticas y de consumo. Se espera que los consumidores modifiquen su demanda de acuerdo a un factor de cambio determinado por el EMS, tal que minimice los costos de operación de la micro-red en un periodo T. Por lo tanto, la predicción de demanda considerando DSM quedaría como sigue:

$$P_L(t) = S_L(t) \cdot \tilde{P}_L(t) \quad (6)$$

Con: $S_L(t)$:Factor de cambio; $P_L(t)$: Predicción de carga.

Tomando en cuenta que los consumidores no responderán con total rigurosidad a la señal que se les entregue, el factor de cambio es un valor acotado.

$$S_{Lmin}(t) < S_L(t) < S_{Lmax}(t) \quad (7)$$

Así, si S_{Lmin} es 0.9, se espera que los usuarios disminuyan su consumo esperado en un 10% y si S_{Lmax} es 1.1, los usuarios podrían aumentar su consumo un 10% sobre lo esperado. Además se asume que durante un periodo de tiempo (T_2-T_1), la energía demandada se mantendrá constante, es decir, los consumidores trasladan su demanda en el tiempo.

$$\sum_{t=T_1}^{T_2} \tilde{P}_L(t) = \sum_{t=T_1}^{T_2} P_L(t) \quad (8)$$

Mediante simulaciones, se compararon los costos de diésel entre utilizar y no utilizar gestión de demanda, para un día con alta y otro con baja irradiación solar. Para el caso con alta irradiación, se obtuvo un ahorro de entre 0.25 y 3.06% para distintos rangos de desplazamiento, comparado con el caso sin gestión de demanda, mientras que para el caso con baja irradiación se obtuvieron ahorros de entre 0.06 y 1.88%.

Otro trabajo realizado, [72], incorpora el concepto de gestión de demanda activa (ADSM) el cual se refiere a un sistema de gestión de demanda con un control automático de las cargas residenciales. Los autores aplican este tipo de gestión mediante un controlador basado en redes neuronales artificiales (ANNs), para potenciar el auto-consumo en una casa que cuenta con generación fotovoltaica, es decir, reducir el consumo desde la red y maximizar el consumo desde el generador fotovoltaico y el sistema de baterías. Esta gestión de demanda corresponde a un control directo de carga, en donde varios controladores basados en ANNs se localizan en los

diferentes artefactos de manera de programar su funcionamiento, para cumplir el objetivo de potenciar el auto-consumo de las casas. Para realizar esto se dividieron las cargas en dos tipos:

Cargas prorrogables: Corresponden a cargas cuyo funcionamiento puede ser desplazado en el día, siendo el usuario quien impone los límites horarios para su funcionamiento. Por ejemplo la lavadora debe funcionar entre las 10hrs y 16hrs.

Cargas no-prorrogables: Son cargas no controlables, las cuales pueden ser instantáneas como prender la luz o la televisión, o de consumo permanente como los refrigeradores.

Las entradas al sistema corresponden a la información del usuario y la predicción de generación. La información del usuario contiene las tareas que estos quieren realizar en las siguientes 24 horas y en el intervalo en que requieren que estas tareas sean ejecutadas. La predicción de generación corresponde a la generación esperada de los paneles solares para las próximas 24 horas, con pronósticos por cada una. A la salida del sistema se tiene la programación para las tareas, logrando maximizar el auto-consumo y dando prioridad a las necesidades del usuario al tomarlo como una de las entradas del sistema, sin que las tareas se traslapen.

En la Figura 15 se tiene la arquitectura del sistema de control propuesto para una micro-red, la cual consiste en tres módulos fundamentales. El módulo de planificación (Scheduler) es responsable de definir los tiempos en que deben ser ejecutadas las tareas, tomando en cuenta las restricciones impuestas por los consumidores y las predicciones de generación fotovoltaica. Este módulo está compuesto por los artefactos domésticos, los cuales tienen asignados cada uno una red neuronal artificial, a modo de controlador. Estos controladores reciben la información entregada por el consumidor, sobre el artefacto al cual están relacionadas y entregan la planificación para dicho artefacto. A continuación se encuentra el coordinador (Coordinator), el cual recibe la información entregada por los controladores y modifica, si es necesario, los tiempos programados para que las tareas no se traslapen, por lo que como entradas recibe, además, los tiempos de duración de las tareas realizadas por los artefactos. Esta capa también está compuesta por ANNs, las cuales llevan a cabo la coordinación de las tareas, con la restricción de que el funcionamiento de los artefactos no se superponga. Finalmente se tiene el actuador (Actuator), el que comunica la capa de coordinación con el artefacto. Éste se encarga de encender los artefactos en el momento indicado por el coordinador, para así dar lugar al inicio de la tarea requerida por el consumidor.

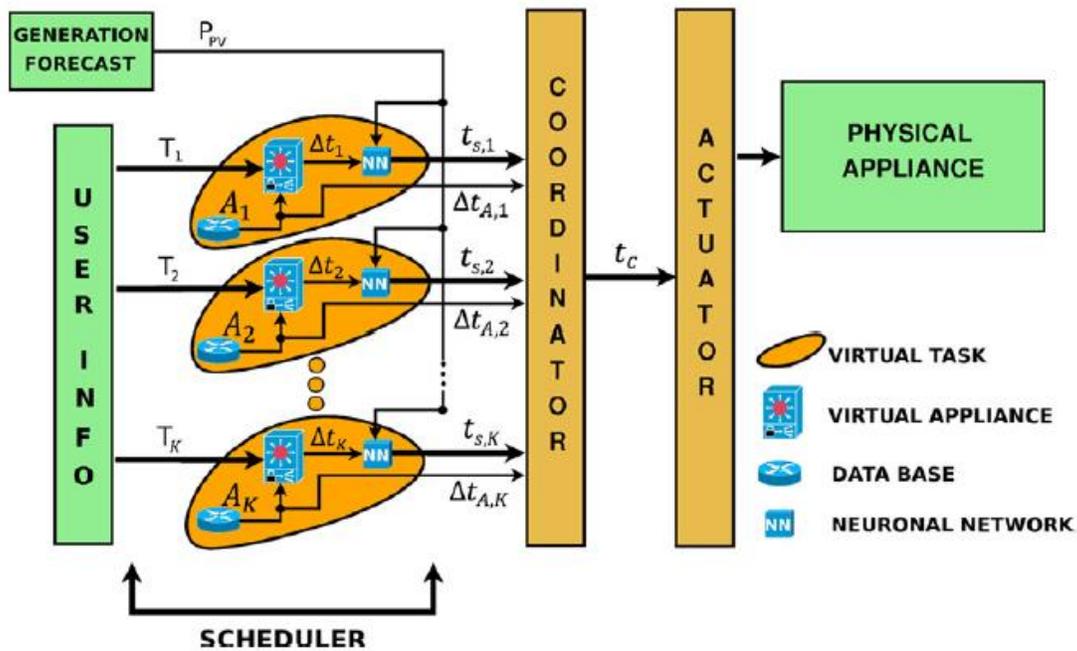


Figura 15: Arquitectura del sistema de control ADSM [72]

En la Figura 16 se puede observar cómo queda programado el funcionamiento de tres artefactos (App1, App2 y App3), t_{sch} corresponde al momento en el que deberían funcionar todos los artefactos si no se tuviera la condición de que su funcionamiento no debe traslaparse, ya que en una etapa inicial los artefactos se programan en forma separada sin tomar en cuenta el resto de los consumos por lo que tienden a ser programados para el mismo momento. De este problema se encarga la última etapa del proceso, el coordinador, como se explicaba anteriormente.

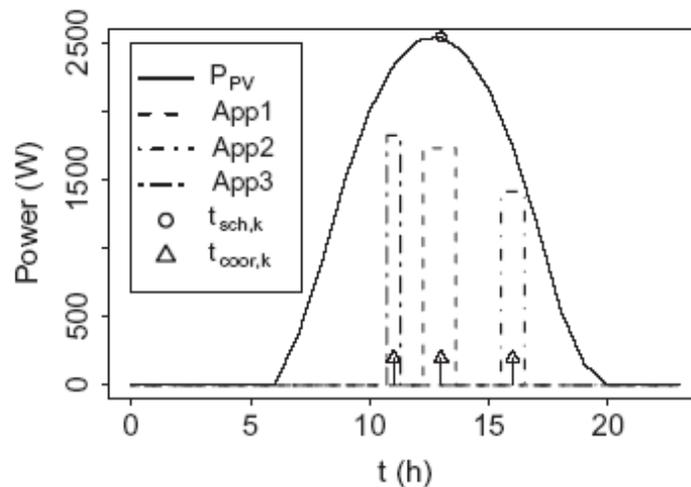


Figura 16: Respuesta final del sistema ADSM

Uno de los principales incentivos para que los consumidores participen de los programas de gestión de demanda son los precios de la energía, como se mencionó en la sección anterior para redes eléctricas en general lo que también se aplica en micro-redes.

Además, se tienen otros trabajos, como en [73], en donde propone un mecanismo basado en mercados en donde el operador de la micro-red (SMO: Smart micro-grid operator) puede manejar el comportamiento de las cargas a través de señales de precios y dar información al operador del mercado de energía (ISO: independent system operator) el cual provee de energía y compra reservas. Este sistema permite que las cargas sean parte del mercado, así como lo son los generadores a través del SMO.

En [74] se presente un sistema multi-agente (MAS) para realizar gestión de demanda, el cual consiste en agentes de carga, agentes de generación y agentes de gestión de demanda. Este trabajo de basa en reducción y desplazamiento de carga, teniendo como objetivo disminuir los costos operacionales, aumentando el uso de energías renovables. Para esto se propone una estrategia inteligente que permite que los agentes controlen los dispositivos controlables que tienen asociados, dependiendo de los cambios en el mercado, pudiendo así adaptar su estrategia de oferta de manera acorde. Además, los agentes están capacitados para mover carga a horas fuera de peak para disminuir costos de operación. Las simulaciones realizadas resultaron en curvas de demanda con comportamientos más suaves.

Finalmente, en [75] se propone utilizar estrategias de precios dinámicos para controlar la demanda durante las horas peak. La estrategia se basa en una juego de red de congestión, en donde el jugador es el usuario, el conjunto de estrategias del juego es la distribución de demanda deseada a lo largo del día y la función de costos son los jugadores aspirando a minimizar el cobro por la energía que utilizan. En general cada consumidor ubicara su demanda como respuesta de las acciones de otros consumidores, lo que en dicho trabajo se comprueba converge a un punto de equilibrio estable. También se prueba que dicho punto además de ser óptimo para el jugador “egoísta”, lo es también para todo el sistema. Finalmente, como resultado de simulaciones se obtiene una curva de carga con un comportamiento más suave que evita los peaks.

4.3.3 Discusión

El objetivo principal de los programas de gestión de demanda es aumentar la eficiencia energética, realizando acciones en el lado de la demanda, lo que beneficia tanto a consumidores como a generadores. Las principales técnicas de gestión se clasifican en control de carga y respuesta de la demanda, la primera corresponde a intervenir las cargas de manera directa o interrumpiendo el servicio eléctrico a consumidores con los cuales se ha llegado a acuerdo previamente, mientras que la segunda corresponde a programas de incentivos para cambiar los patrones de comportamiento de los consumidores. Los incentivos para los programas de respuesta de la demanda, suelen ser principalmente monetarios.

La utilización de gestión de demanda, en micro-redes basadas en energías renovables, se hace relevante debido a las fluctuaciones que presentan este tipo de fuentes de energía y la importancia

que tiene mantener el equilibrio entre generación y demanda. Diversos trabajos respaldan los beneficios de utilizar gestión de demanda en sistemas donde se tiene una alta penetración de energías renovables no convencionales, disminuyéndose la necesidad de utilizar combustibles como el diésel o el gas, lo que se traduce en una disminución de los costos. Para este tipo de redes, los principales tipos de gestión de demanda son; control directo de carga y respuesta de la demanda, utilizando señales de precios para incentivar la participación de los consumidores.

Un factor importante para mantener el equilibrio entre demanda y generación, es tener una predicción de demanda eléctrica confiable, lo que se hace más crítico para micro-redes basadas en energías renovables, debido a la fluctuación que se ha mencionado anteriormente. Dentro de este contexto, la siguiente sección trata sobre el desarrollo de un módulo de predicción de demanda para micro-redes, el cual se pretende sea más certero que el previamente realizado para la misma micro-red, utilizando redes neuronales. Además, para asegurar el buen funcionamiento de este módulo, también se realiza el estudio de estabilidad del modelo difuso desarrollado para predecir demanda.

También, para tratar el problema del equilibrio entre demanda y generación se propone en el capítulo subsiguiente mejoras para un sistema de gestión de demanda basado en la respuesta de la demanda. Estas mejoras consisten en modelar el factor de desplazamiento de carga utilizando información histórica y modelar el comportamiento de los consumidores ante las señales de gestión de demanda.

5 Predicción de demanda basada en modelación difusa de Takagi y Sugeno

En el presente capítulo se presenta el desarrollo del módulo de predicción de demanda para micro-redes utilizando modelación difusa, realizado en este trabajo. La razón para utilizar este tipo de modelación, es el comportamiento no lineal que presenta la demanda eléctrica en micro-redes. Se utiliza para esto el modelo difuso de Takagi y Sugeno, entrenándolo con datos históricos, de modo que relacione la demanda futura con la demanda del día anterior. El modelo se utilizará para predecir la demanda eléctrica de los dos días siguientes, debido a que estas predicciones serán utilizadas en sistema de gestión de energía instalado en la micro-red de Huatacondo, el cual trabaja realizando los despachos de las unidades generadoras, tomando la información de predicciones a dos días.

En la primera parte se introducen los modelos difusos de Takagi y Sugeno, a continuación la metodología de identificación típica, utilizada para modelación difusa y finalmente se tratará el análisis de estabilidad, el cual en esta tesis se incluye como una nueva etapa en el proceso de identificación del modelo. Luego, se presenta el desarrollo del módulo de predicción de demanda y los resultados obtenidos para la predicción a dos días. Luego, se compara el desempeño de la predicción, realizando un análisis comparativo entre el modelo desarrollado con modelación difusa y un modelo que utiliza redes neuronales [10]. Finalmente, se realiza un análisis a la estabilidad del modelo construido, para lo cual se detallan algunas de las técnicas más utilizadas para analizar estabilidad de sistemas difusos.

A continuación se describe la estructura del modelo difuso propuesto por Takagi y Sugeno, el cual será utilizado posteriormente, como se mencionó, para realizar predicción de demanda eléctrica en micro-redes.

5.1 Modelos difusos de Takagi y Sugeno

Un sistema estático o dinámico que utiliza conjuntos difusos o lógica difusa y el correspondiente marco matemático, es llamado sistema difuso [76]. Existen diversas clases de modelos difusos, dependiendo de la forma que tienen las reglas y en como se organizan en la base de éstas. En esta sección se tratarán los modelos difusos de Takagi y Sugeno. En estos modelos las premisas corresponden a conjuntos difusos en el espacio de entrada, mientras que las consecuencias son funciones lineales de las entradas del modelo. Este tipo de estructura es capaz de representar sistemas estáticos o dinámicos no lineales [77].

En el modelo difuso propuesto por Takagi y Sugeno (1985), la estructura de las premisas describe regiones difusas en el espacio de entrada, y las consecuencias corresponden a funciones lineales (no difusas) de las entradas del modelo.

Estos modelos, para sistemas dinámicos, tienen el siguiente formato:

$$R_i: \text{Si } y(t-1) \text{ es } A_{i,1} \text{ y } \dots \text{ y } y(t-n) \text{ es } A_{i,n} \text{ y } u(t-1) \text{ es } B_{i,1} \text{ y } \dots \text{ y } u(t-m) \text{ es } B_{i,m} \\ \text{entonces } y_i(t) = a_{i,1}y(t-1) + \dots + a_{i,n}y(t-n) + b_{i,1}u(t-1) + \dots + b_{i,m}u(t-m) + c_i$$

En donde: $y(t)$: Variable de salida; $u(t)$: Entrada del sistema; $A_{i,1}, \dots, A_{i,n}$: Conjuntos difusos de las premisas; $a_1^i, \dots, a_n^i, b_1^i, \dots, b_m^i, c^i$: Parámetros de las consecuencias que describen una relación entrada-salida en casa subespacio difuso..

La salida del modelo Y , está dada por la ponderación de la salida de cada regla por su respectivo grado de cumplimiento W_i .

$$Y(t) = \frac{\sum_{i=1}^R (W_i y_i)}{\sum_{i=1}^R W_i} \quad (9)$$

En la Figura 17 se observa como se aproxima una función utilizando el modelo estático de Takagi y Sugeno, esto es, mediante la combinación de modelos lineales locales.

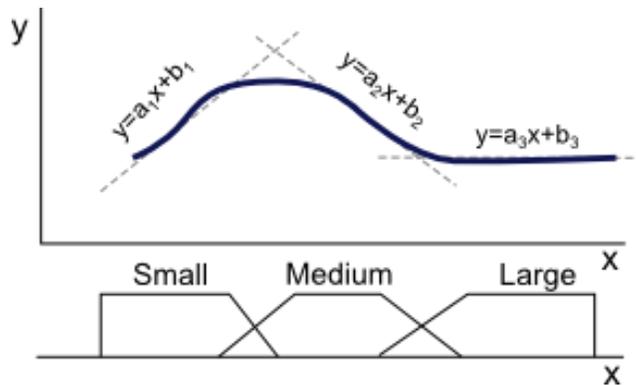


Figura 17: Aproximación lineal con modelo de Takagi y Sugeno [78]

5.2 Metodología de identificación difusa

En la Figura 18, se observa el proceso de identificación para construir el modelo difuso, el cual se detalla a continuación [79].

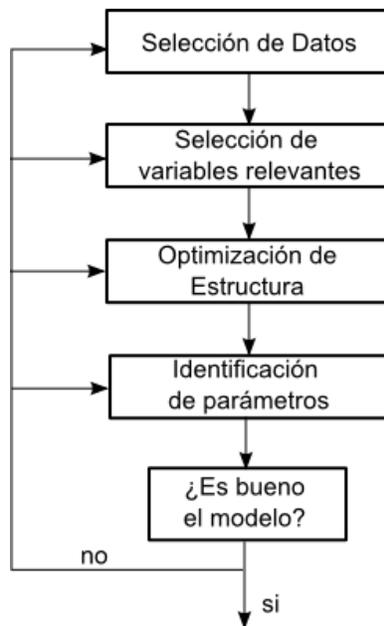


Figura 18: Identificación modelo difuso [79]

Selección de datos: El primer paso corresponde a escoger los conjuntos de datos a utilizar, éstos son el conjunto de entrenamiento, de prueba y de validación. El primero se utiliza para determinar los parámetros del modelo. El conjunto de prueba permite evaluar el modelo bajo un nuevo set de datos y de esta manera obtener su estructura. Finalmente, el conjunto de validación sirve para evaluar el modelo ajustado utilizando nuevos datos.

Selección de variables relevantes: Esta etapa consiste en elegir las variables de entrada al modelo que tengan mayor relación con la salida. Esta selección, se puede relizar a partir del conocimiento que se tenga del sistema que se quiere modelar o llevando a cabo diversos métodos, como el análisis de sensibilidad [80].

Optimización de estructura: Esta etapa consiste en el procedimiento por el cual se elige la estructura óptima. Para esto se proponen diferentes arquitecturas aumentando la complejidad, luego, para cada arquitectura propuesta, la optimización se lleva a cabo minimizando el índice RMSE (Root Mean Square Error) de entrenamiento y evaluando el error RMSE de prueba. Esto se hace hasta que ambos errores aumenten o se estabilicen. El RMSE está dado por:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (10)$$

Con y_i la salida real del modelo en i , \hat{y}_i la salida predicha para i y N el número de datos.

Identificación de parámetros: En esta etapa se realiza el clustering difuso y se identifican los parámetros de las premisas. Un cluster corresponde a un conjunto de datos que poseen algún

atributo en común. En clustering difuso, los elementos que componen los clusters tienen asociado un grado de pertenencia entre 0 y 1, a cada cluster, pudiendo un mismo elemento ser parte de múltiples cluster con distinto grado de pertenencia a cada uno. Para determinar los clusters difusos se realiza una partición del espacio y se le asigna un grado de pertenencia a cada elemento del espacio. El algoritmo más utilizado para realizar esto corresponde a “fuzzy C-Means clustering”, que se basa en la optimización de un funcional que representa matemáticamente la existencia de similitud entre los datos.

Por otra parte, para obtener los parámetros de las consecuencias se puede utilizar mínimos cuadrados de dos maneras [81].

Método 1: La primera consiste en minimizar, para cada cluster, el error cuadrático entre la función $y_i(t)$ y la porción correspondiente de datos de salida. Por lo tanto, se desea minimizar la siguiente función de costo, para el j -ésimo cluster:

$$J_j = \sum_{i=1}^M u_{ij}^2 (y^i - (\hat{x}^i)^T \tilde{a}_j)^2 \quad (11)$$

En donde u_{ij} corresponde al grado de pertenencia del par de datos $d_i = (x^i, y^i)$ al clúster j -ésimo. Finalmente, y^i corresponde a los datos de salida pertenecientes a la porción que abarca el clúster j , \hat{x}^i son los valores que toman los parámetros de la función de salida de la regla i , y $(\hat{x}^i)^T \tilde{a}_j$ es la salida estimada, asociada al clúster j , para el par d_i . El parámetro \tilde{a}_j que minimiza la función de costo esta dada por:

$$\tilde{a}_j = (\hat{X}^T D_j^2 \hat{X})^{-1} \hat{X}^T D_j^2 Y \quad (12)$$

Con:

$$\begin{aligned} \hat{X} &= \begin{bmatrix} 1 & \dots & 1 \\ x^1 & \dots & x^M \end{bmatrix}^T \\ Y &= [y^1, \dots, y^M]^T \\ D_j^2 &= \left(\text{diag}([u_{1j}, \dots, u_{Mj}]) \right)^2 \end{aligned}$$

Método 2: La segunda forma para determinar los parámetros, consiste en utilizar mínimos cuadrados sobre todo el sistema y no separando por reglas. Para esto se parametriza la salida del sistema de forma que sea lineal en los parámetros de las consecuencias y de la forma:

$$f(x|\theta) = \theta^T \xi(x) \quad (13)$$

Esto quedaría:

$$Y = \frac{\sum_{i=1}^R a_{i0} W_i}{\sum_{i=1}^R W_i} + \frac{\sum_{i=1}^R a_{i1} x_1 W_i}{\sum_{i=1}^R W_i} + \dots + \frac{\sum_{i=1}^R a_{in} x_n W_i}{\sum_{i=1}^R W_i} \quad (14)$$

Si se define:

$$\xi_i = \frac{W_i}{\sum_{i=1}^R W_i} \quad (15)$$

$$\xi = [\xi_1, \dots, \xi_R, \xi_1 x_1, \dots, \xi_R x_1, \dots, \xi_1 x_n, \dots, \xi_R x_n]^T \quad (16)$$

$$\theta = [a_{10}, a_{20}, \dots, a_{R0}, a_{11}, a_{21}, \dots, a_{R1}, \dots, a_{1n}, a_{2n}, \dots, a_{Rn}] \quad (17)$$

Entonces se puede escribir $Y = f(x|\theta) = \theta^T \xi(x)$, teniéndose un sistema lineal en los parámetros, los cuales pueden ser estimados utilizando mínimos cuadrados.

5.3 Análisis de estabilidad

En la presente sección, se presentaran las diversas metodologías que existen para analizar la estabilidad de los sistemas difusos, específicamente los planteados por Tanaka y Sugeno, de modo de poder elegir la más adecuada para analizar el modelo de predicción de demanda eléctrica.

El análisis de estabilidad de sistemas difusos ha sido difícil, ya que los sistemas difusos son esencialmente sistemas no-lineales [82]. Principalmente, se utiliza el método de Lyapunov para análisis de estabilidad de sistemas difusos, por lo que en la siguiente sección también se presenta una revisión de este método, para luego detallar las técnicas que lo utilizan como herramienta para realizar el análisis de estabilidad.

5.3.1 Estabilidad según Lyapunov

El teorema de estabilidad de Lyapunov fue propuesto hace más de 100 años y es uno de los teoremas más importantes en control. Las funciones de Lyapunov son las herramientas básicas para analizar la estabilidad de sistemas no lineales [83]. Los teoremas de estabilidad de Lyapunov establecen propiedades para los puntos de equilibrio, o más generalmente para los sistemas no-lineales, estudiando como ciertas funciones escalares, escogidas cuidadosamente, evolucionan mientras los estados del sistemas evolucionan [84]. Un punto de equilibrio se dice estable si todas las soluciones que se inician en las cercanías del punto de equilibrio permanecen en las cercanías del punto de equilibrio; de otro modo el punto de equilibrio es inestable. Por otro lado, un punto de equilibrio es asintóticamente estable si todas las soluciones que se inician en las cercanías de él no solo permanecen en las cercanías del punto de equilibrio, sino que además tienden hacia dicho punto a medida que el tiempo se aproxima a infinito.

El teorema de estabilidad de Lyapunov es el siguiente:

Teorema 1 [85]: Sea el origen $x = 0$ un punto de equilibrio de $\dot{x} = Ax$ y sea $D \subset \mathbb{R}^n$ un dominio que contiene el origen. Sea $V: D \rightarrow \mathbb{R}^n$ una función continuamente diferenciable tal que:

$$V(0) = 0 \text{ y } V(x) > 0 \text{ en } D - \{0\} \quad (18)$$

$$\dot{V}(x) \leq 0 \text{ en } D \quad (19)$$

Entonces $x = 0$ es estable. Más aún, si:

$$\dot{V}(x) < 0 \text{ en } D - \{0\} \quad (20)$$

Entonces $x = 0$ es asintóticamente estable.

5.3.2 Métodos para el análisis de estabilidad

A continuación se presentan métodos para analizar la estabilidad de sistemas difusos de Takagi y Sugeno.

Estabilidad Cuadrática

Se puede analizar la estabilidad de los modelos difusos de Takagi y Sugeno utilizando el método directo de Lyapunov, con la siguiente función cuadrática como función de Lyapunov [86]:

$$V(x) = x^T P x \quad (21)$$

Con $P = P^T > 0$.

Cuando se utiliza esta función se considera estabilidad cuadrática. Cuando un sistema es cuadráticamente estable implica que también es estable. Sin embargo, lo contrario no es necesariamente cierto, por lo que si el sistema no resulta ser cuadráticamente estable no es necesariamente inestable.

La derivada de la función cuadrática para realizar el análisis de estabilidad según Lyapunov es:

$$\dot{V} = \left(\sum_{i=1}^r w_i A_i x \right)^T P x + x^T P \left(\sum_{i=1}^r w_i A_i x \right) = \sum_{i=1}^r w_i x^T (A_i^T P + P A_i) x \quad (22)$$

Con lo que se puede enunciar el siguiente teorema:

Teorema 2: El modelo no forzado $\dot{x} = \sum_{i=1}^r w_i A_i x$ es global y asintóticamente estable si existe una matriz $P = P^T$ tal que se cumple la siguiente desigualdad matricial lineal (LMI):

$$\mathcal{H}(PA_i) < 0 \quad (23)$$

Para $i = 1, \dots, r$, en donde \mathcal{H} corresponde a la parte simétrica, es decir $\mathcal{H}(X) = X + X^T$

De este teorema se desprende la siguiente propiedad. Si existen matrices definidas positivas $R_i = R_i^T, i = 1, \dots, r$, tal que:

$$\sum_{i=1}^r (A_i^T R_i + R_i A_i) > 0 \quad (24)$$

Entonces no hay matriz $P = P^T > 0$ tal que se cumpla el teorema recién enunciado.

D-Estabilidad

Un subconjunto D del plano complejo es llamado región LMI (linear matrix inequality) si existe una matriz simétrica $X \in R^{r \times n}$ y una matriz $Y \in R^{r \times r}$ tal que:

$$D = \{z | z \in C, f_D(z) < 0\} \quad (25)$$

Donde $f_D(z) = X + zY + \bar{z}Y^T$ es la función característica de la región LMI.

En la Figura 19 se observa la región LMI, la cual es convexa con respecto al eje imaginario y simétrica con respecto al eje real, debido a la forma de la función $f_D(z)$. Si todos los valores propios de una matriz A se encuentran dentro de la región LMI, entonces se dice que la matriz A es D-estable.

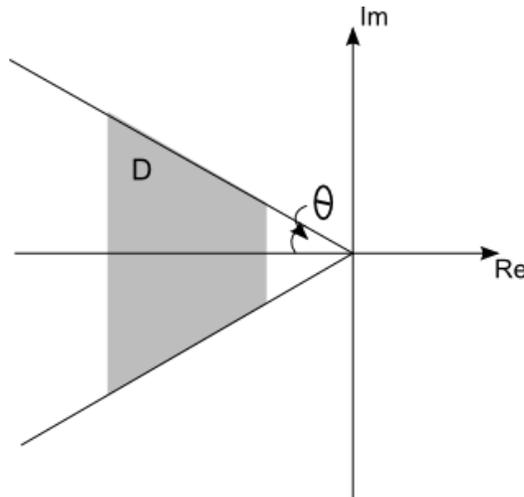


Figura 19: Región LMI [86]

El siguiente teorema asegura la D-estabilidad de una matriz A.

Teorema 3: La matriz A es D-estable si y solo si existe $P = P^T > 0$ tal que:

$$X \otimes P + Y \otimes AP + Y^T \otimes (AP)^T < 0 \quad (26)$$

En donde \otimes es el operador Kronecker, que se define como sigue.

$$\begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix} \otimes [b_1 \quad b_2 \quad b_3 \quad b_4] = \begin{bmatrix} a_1 b_1 & a_1 b_2 & a_1 b_3 & a_1 b_4 \\ a_2 b_1 & a_2 b_2 & a_2 b_3 & a_2 b_4 \\ a_3 b_1 & a_3 b_2 & a_3 b_3 & a_3 b_4 \end{bmatrix}$$

Existencia de matriz P

Los siguientes teoremas permiten analizar la estabilidad de sistemas difusos discretos, al establecer la existencia o no de una matriz P.

Teorema 4 [87]: El sistema $x(t + 1) = Ax(t)$ es asintóticamente estable si existe una matriz común P tal que:

$$A_i^T P A_i - P < 0 \quad (27)$$

Para $i = 1, \dots, r$.

Se debe notar que aunque cada subsistema sea estable, la existencia de P no está garantizada. El siguiente teorema da una condición suficiente para la existencia de P.

Teorema 5 [87]: Asumiendo que A_i es estable y no-singular para $i = 1, \dots, m$. Con A_i la matriz que contiene los parámetros de las consecuencias de la regla i, en un modelo difuso, teniendo la siguiente forma:

$$A_i = \begin{bmatrix} a_{i,1} & a_{i,2} & \dots & \dots & a_{i,n} \\ 1 & 0 & \dots & \dots & 0 \\ 0 & 1 & & & \vdots \\ \vdots & & \ddots & & \vdots \\ 0 & \dots & 0 & 1 & 0 \end{bmatrix}$$

La matriz $A_i A_j$, con $i, j = 1, \dots, r$, es estable si y solo si existe una matriz común definida positiva P, tal que:

$$A_i^T P A_i - P < 0 \quad (28)$$

Demostración: De $A_i^T P A_i - P < 0$ se tiene $P - (A_i^{-1})^T P A_i^{-1} < 0$ dado que $(A_i^{-1})^T = (A_i^T)^{-1}$. Entonces, $P < (A_i^{-1})^T P (A_i^{-1})$ para $i = 1, \dots, r$. Y dado que $A_i^T P A_i < P$, entonces para $i, j = 1, \dots, r$, se tiene que:

$$A_i^T P A_i < (A_j^{-1})^T P (A_j^{-1}) \quad (29)$$

De esta desigualdad se obtiene entonces:

$$A_j^T A_i^T P A_i A_j - P < 0 \quad (30)$$

Por lo que $A_i A_j$ debe ser estable para $i, j = 1, \dots, r$.

5.3.3 Metodología propuesta para el análisis de estabilidad de modelos difusos

Basándose en el teorema 5, se desarrolló una metodología para analizar la estabilidad del sistema difuso, a través de las matrices de estado de éste, la cual se analiza a continuación. Luego, esta metodología fue implementada en Matlab de manera de obtener un programa que analice la estabilidad del sistema. El código de dicho programa se encuentra en el anexo E y el diagrama de flujo la metodología se puede observar en la Figura 20.

Entrada: Para la metodología de análisis de estabilidad, se considera como entrada una matriz que contiene los parámetros de las consecuencias de cada regla difusa. Entonces, para un modelo difuso de Takagi y Sugeno de la siguiente forma:

$$R_i: \text{Si } y(t-1) \text{ es } A_{i,1} \text{ y } \dots \text{ y } y(t-n) \text{ es } A_{i,n} \text{ y } u(t-1) \text{ es } B_{i,1} \text{ y } \dots \text{ y } u(t-m) \text{ es } B_{i,m} \\ \text{entonces } y_i(t) = a_{i,1} y(t-1) + \dots + a_{i,n} y(t-n) + b_{i,1} u(t-1) + \dots + b_{i,m} u(t-m) + c_i$$

La matriz de entrada tendría la estructura que se muestra a continuación, considerando r reglas y 96 regresores.

$$G = \begin{bmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,96} \\ \vdots & & & \vdots \\ a_{r,1} & a_{r,2} & \dots & a_{r,96} \end{bmatrix}$$

Confección de r matrices: La siguiente etapa corresponde a construir las r matrices que representan el modelo en variables de estado. Estas matrices quedan como se muestra a continuación.

$$A_i = \begin{bmatrix} a_{i,1} & a_{i,2} & \dots & \dots & a_{i,96} \\ 1 & 0 & \dots & \dots & 0 \\ 0 & 1 & & & \vdots \\ \vdots & & \ddots & & \vdots \\ 0 & \dots & 0 & 1 & 0 \end{bmatrix}$$

Singularidad A_i : El teorema exige que las matrices no sean singulares, por lo tanto se calcula el determinante de las r matrices y se asegura que sea distinto de cero. Si uno de los determinantes es cero el proceso termina y no se puede analizar el sistema utilizando esta técnica, por lo tanto, no se asegura estabilidad. Si ninguna de las matrices es singular, se continúa con las siguientes etapas.

Estabilidad A_i : La estabilidad de las matrices se analiza a través de sus polos. Como se trata de un sistema discreto, se busca que los polos se encuentren dentro del círculo unitario. Si alguna de las matrices resulta no ser estable, entonces se termina el proceso y se determina que el sistema es inestable. En el caso en que todas las matrices sean estables, entonces se continúa a la siguiente etapa.

Estabilidad $A_i A_j$: Luego se multiplican las matrices, obteniéndose $r \times r$ nuevas matrices a las que se les realiza el mismo análisis anterior para determinar si son estables. Si alguna de estas resulta no ser estable, entonces el proceso termina y se establece que el modelo es inestable. Si todas las matrices resultan ser estables, entonces el modelo es estable y el proceso de análisis termina.

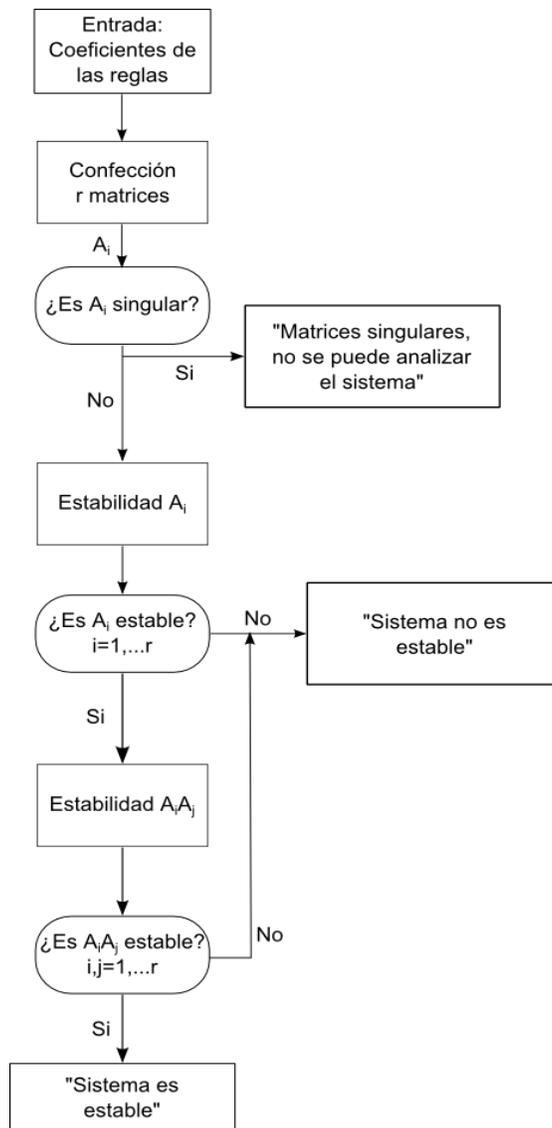


Figura 20 : Metodología para el análisis de estabilidad de modelos difusos de Takagi y Sugeno

5.4 Desarrollo de un módulo de predicción de demanda para utilizar en un sistema de gestión de energía (EMS)

En la presente sección se detalla el desarrollo de un módulo de predicción de demanda, el cual está formulado para ser utilizado como parte de un sistema de gestión de energía para micro-redes basadas en energía renovable.

5.4.1 Caso de estudio

El EMS (Energy Management System), propuesto en [88], se basa en la estrategia de horizonte deslizante para una micro-red basada en energías renovables. Para la decisión de cada paso se resuelve un problema de optimización basado en modelos de pronóstico. El EMS minimiza los costos operacionales, mientras satisface la demanda de agua y energía eléctrica, considerando pronósticos de recursos renovables y de demanda para dos días. Se considera el horizonte deslizante para reducir el efecto de la incerteza que contemplan los pronósticos utilizados como entradas. En esta sección se trata el desarrollo del bloque de predicción de demanda eléctrica, cuyo comportamiento es importante para realizar una buena optimización del despacho eléctrico.

Este bloque de predicción de demanda se relacionará con el sistema de gestión de demanda (DSM) diseñado, siendo sometido a una corrección al tomar en cuenta el comportamiento de los consumidores ante las señales que se les envíen. Por lo tanto la entrada al EMS será la predicción corregida por el bloque de gestión de demanda.

Para realizar la predicción de la demanda se utilizó el modelo difuso de Takagi y Sugeno. Es importante para la identificación, utilizar datos reales del proceso, que incluyan suficiente información para modelar el comportamiento del sistema que se desea representar. En este caso se cuenta con un conjunto de datos que abarca desde el mes de Diciembre del año 2010 a Mayo del 2011. Los datos son obtenidos cada 15 minutos, por lo tanto un día consta de 96 mediciones. En el siguiente gráfico se tiene el consumo promedio de marzo, para un día en la micro-red de Huatacondo.

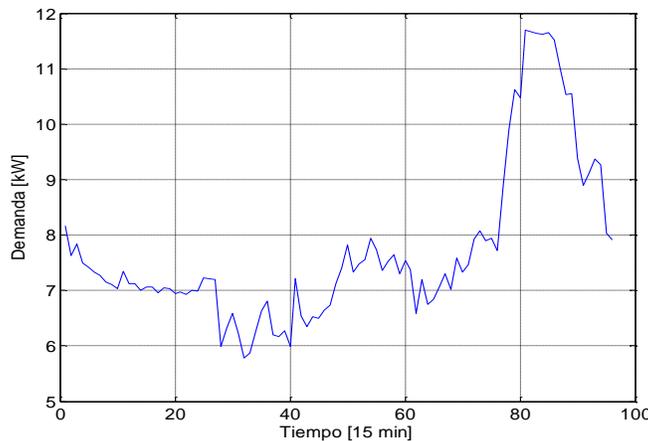


Figura 21: Demanda eléctrica promedio durante Marzo 2011 en Huatacondo

5.4.2 Identificación del modelo

Para la construcción del modelo de predicción de demanda, se aplica una metodología de identificación basada en la que se presenta en la sección 5.2, a la cual se le agrega el análisis de estabilidad y se modifica el orden en que se aplican las etapas, quedando como se muestra en la Figura 22. Las etapas se detallan a continuación.

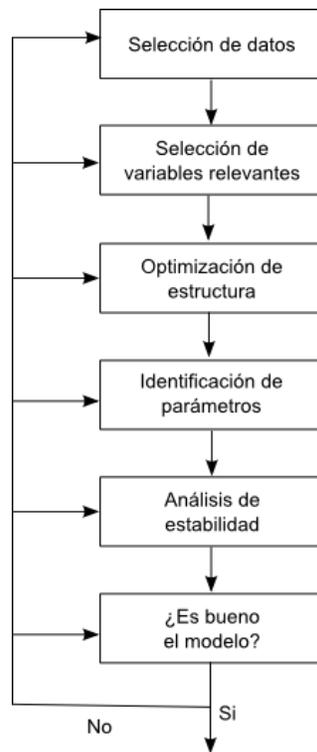


Figura 22: Metodología de identificación utilizada para el modelo de predicción de demanda

Selección de variables relevantes.

Para la elección de las variables a utilizar, se analizaron las correlaciones entre ellas, para elegir como entradas al modelo las que tuvieran mayor relación con la demanda futura. Para esto se utilizaron las correlaciones calculadas en [89] para la micro-red de Huatacondo, siendo las variables analizadas la temperatura, velocidad del viento, potencia solar, humedad y demanda, dado que son las variables de las cuales se cuenta con medidas. El estudio de estas correlaciones resulta en que la demanda tiene una baja correlación con respecto a las variables climáticas debido a la baja variación que tienen estas día a día, y una mayor correlación con los datos pasados de consumo, por lo que para el modelo se tendrá que los datos de consumos futuros son función de los datos de consumos pasados, por lo tanto, el modelo difuso tendrá la siguiente forma:

$$y(t) = F(y(t - 1), y(t - 2), \dots, y(t - 96)) \quad (31)$$

Con $y(t)$, el consumo predicho para el tiempo t y $F(\cdot)$, la relación no lineal dado por el modelo difuso.

Selección de datos

Para realizar y validar el modelo, se dividieron los datos en tres conjuntos. El primer conjunto corresponde al de entrenamiento, correspondiendo al 40% de los datos (5644 registros) y se

utilizó para definir los parámetros del modelo. Luego, se tiene un conjunto de prueba, con el 40% siguiente de datos para evaluar el modelo y el 20% restante de los datos se utilizó para realizar la validación final del modelo. Las fechas que abarcan estos conjuntos son las siguientes:

Tabla 3: Conjuntos para realización del modelo

Conjunto	Fecha Inicio	Fecha Fin
Entrenamiento	12-Diciembre 2010	8-Febrero-2011
Prueba	8-Febrero-2011	10-Abril-2011
Validación	10-Abril-2011	9-Mayo-2011

Identificación de parámetros

Para obtener los parámetros de las consecuencias se utilizarán los dos métodos de mínimos cuadrados vistos en la sección 5.2. Desde ahora en adelante el modelo que utiliza el método de minimización del error cuadrático para cada clúster se denominará TKS21, mientras que el modelo que utiliza el método de mínimos cuadrados sobre todo el sistema, se denominará TKS11. En la siguiente sección se realizará la elección del mejor modelo.

Optimización de estructura

Para elegir el modelo a utilizar y la cantidad de reglas, se construyeron ambos modelos, TKS11 y TKS21, con diferente cantidad de reglas, lo que coincide con la cantidad de clústers, para compararlos. Utilizando lo propuesto en [79] para elegir la cantidad de clústers, se realiza la estimación de los parámetros minimizando el RMSE para los datos de entrenamiento y se evalúa el error para el conjunto de prueba. En este caso y_i es el consumo real en i , \hat{y}_i es el consumo predicho para i y N es el número de muestras.

Los resultados pueden observarse también en el gráfico de la Figura 23, en donde se observa que para el conjunto de entrenamiento, el RMSE disminuye a medida que aumenta la cantidad de reglas, pero este índice aumenta sostenidamente al utilizar el modelo con el conjunto de prueba. Esto se debe a que el modelo es inestable, lo cual se analiza más adelante. Por lo tanto, por esta razón se descarta esta estructura. También se realizó el mismo estudio para el modelo TKS21, cuyos resultados se pueden apreciar en el gráfico de la Figura 24.

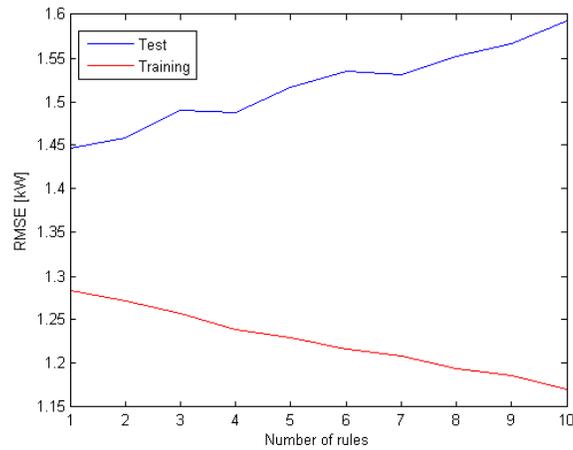


Figura 23: RMSE para el modelo TKS11 en función del número de reglas

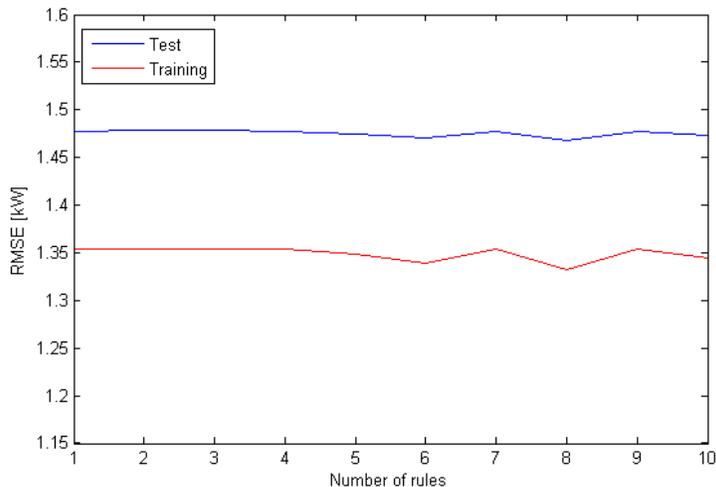


Figura 24: RMSE para el modelo TKS21 en función del número de reglas

En esta figura el índice RMSE presenta una leve disminución al aumentar la cantidad de clusters, por lo tanto se seleccionaron cuatro modelos que presentaban bajo RMSE tanto para el conjunto de entrenamiento como el de prueba, estos son los modelos realizados con 4, 8, 11 y 20 reglas, para continuar con las etapas de identificación del modelo. Utilizando estos cuatro modelos, se calculó el RMSE para el conjunto de validación, cuyos resultados se observan en la

Tabla 4, en donde se puede apreciar que el error no difiere notoriamente para los modelos. Como última prueba para elegir el modelo, se eligieron los datos de un día dentro del conjunto de validación y se realizó predicción a 192 pasos, ya que el objetivo final del bloque de predicción es hacer un pronóstico para un horizonte de 2 días. Para realizar la predicción a 192 pasos se siguió el procedimiento que se presenta más adelante en la sección 5.5. Los resultados para esta última prueba se tienen en la Tabla 5.

Tabla 4: RMSE para el conjunto de validación utilizando TKS21

RMSE [kW]			
N° Reglas	Entrenamiento	Prueba	Validación
4	1.3538	1.4780	1.5632
8	1.3318	1.4683	1.5461
11	1.3297	1.4660	1.5442
20	1.3257	1.4644	1.5402

Tabla 5: RMSE para predicción a 192 pasos

RMSE [kW]	
N° Reglas	192 pasos
4	1.4942
8	1.4928
11	1.4917
20	1.4925

Análisis de estabilidad

A los modelos que fueron seleccionados por tener menor error, construidos con 4, 8, 11 y 20 reglas, se les realizó un análisis de estabilidad, para elegir finalmente cuál de los cuatro era conveniente utilizar. Utilizando la metodología propuesta en la sección 5.3.3, se analizó la estabilidad de estos modelos difusos, comprobando lo dicho inicialmente para el modelo TKS11, el cual aumenta su error al ir aumentando las reglas. Al aplicar la metodología para los modelos construidos con 1 a 5 reglas, se observó que todos estos resultan ser inestables, lo que explica que el error vaya en aumento.

Luego, con el modelo TKS21, el que finalmente fue escogido para realizar la predicción, se realizó el análisis para el modelo que consta de 4, 8, 11 y 20 reglas. De los modelos con 8, 11 y 20 reglas, ninguno pasó la etapa del análisis de estabilidad de las matrices A_i , ya que prácticamente todas ellas eran inestables, por lo tanto, para dicho número de reglas el modelo resultante es inestable. Las 4 matrices de estado, del modelo construido con 4 reglas, resultan ser estables, por lo tanto se pasa a la siguiente etapa, de donde se obtienen 16 matrices. Al realizar el análisis de estas matrices resultaron ser estables, por lo tanto el modelo de predicción de demanda eléctrica, basado en modelación difusa de Takagi y Sugeno, construido con 4 reglas, es estable.

5.4.3 Resultados

Luego de completadas todas las etapas de identificación presentadas en la sección anterior, se llegó a la conclusión de que lo más conveniente es utilizar el modelo difuso de Takagi y Sugeno con las siguientes características:

- El modelo consta de 4 reglas.
- Se utilizan los datos de un día completo como entrada, es decir, 96 regresores.
- Para obtener los parámetros de las consecuencias se aplican mínimos cuadrados a cada regla.
- Clustering difuso es utilizado para determinar los parámetros de las reglas.

A continuación, en la Figura 25 se presenta gráficamente el comportamiento del modelo utilizando 4 reglas. Estos resultados corresponden a hacer predicción a 48 horas, es decir, se utilizan datos conocidos de un día completo (96 registros) para pronosticar los 2 días (192 registros) siguientes.

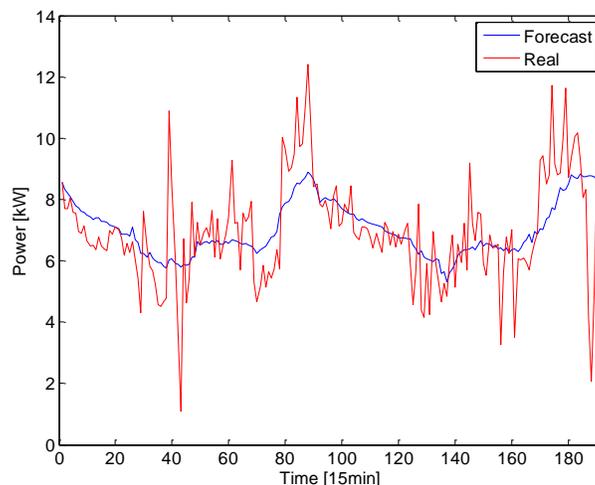


Figura 25: Predicción a 192 pasos.

Del análisis de este gráfico se puede observar que la predicción sigue de cerca los datos reales a excepción de los peaks, los cuales no alcanzan a verse reflejados en el índice RMSE, pero en la operación de la micro-red podrían resultar siendo un problema para la correcta operación. Es difícil predecir este tipo de peaks, por lo que la gestión de demanda resulta una buena herramienta para aminorar los problemas que pudieran suscitarse, sobre todo si se cuenta con un incentivo económico para que los consumidores estén más dispuestos a modificar su demanda eléctrica.

El error que se presenta en ambos conjuntos completos, corresponde al presentado en la Tabla 4 para el modelo con 4 reglas, 1.4780[kW] para el conjunto de prueba y 1.5632[kW] para el

conjunto de validación. El error para el conjunto de validación es mayor que el del conjunto de prueba, como era de esperarse, ya que el conjunto de prueba corresponde a los datos que vienen a continuación del conjunto de entrenamiento y el conjunto de validación se encuentra más alejado de éste, y el comportamiento de los consumidores se modifica levemente a medida que transcurre el tiempo, lo que se analiza más adelante.

Se utilizaron predicciones realizadas con este modelo, en el optimizador del sistema de gestión de demanda. Los resultados se compararon con uno de los casos que se utilizan en [5] para la optimización, el cual será denominado caso original. La predicción realizada a 192 pasos para el caso original y el nuevo, realizadas el modelo de Takagi y Sugeno, se presentan en la Figura 26. El error RMS para la predicción en el caso original es 2.42[kW], mientras que en el nuevo caso es 2.15[kW], obteniéndose una disminución del 11% en el error.

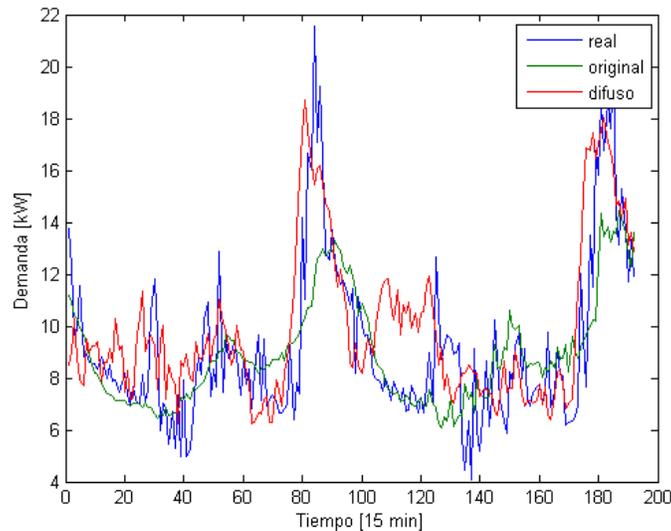


Figura 26: Predicción de demanda utilizada en el optimizador

Esta comparación se realiza en base a los costos finales del despacho simulado, el cual toma en cuenta el caso en donde no se tiene generador eólico y no hay desplazamiento de la demanda, es decir, no hay señales de gestión de demanda que puedan afectar el comportamiento de los consumidores. Los resultados se presentan en la Tabla 6, en donde se tiene la optimización realizada para uno y dos días. Se puede observar una evidente disminución en los costos finales, del 23% al realizar la optimización para un día y del 15% para 2 días, esto debido a que el despacho se realiza con predicciones de demanda más certeras por lo que se puede programar de mejor manera la utilización del diésel.

Tabla 6: Comparación de costos para las distintas predicciones

	1 día		2 días	
	Original	Nuevo	Original	Nuevo
Costo operacional (CLP)	23293,5	11708,9	50855,3	40697,3
Costo partida (CLP)	3000	2000	5000	5000
Costo combustible (CLP)	26293,5	13708,9	55855,3	45697,3
Costo final (CLP)	32263,8	24533,1	59908,5	50343,1

5.4.4 Discusión

Finalmente, para realizar el bloque de predicción de demanda, se decidió utilizar el modelo difuso de Takagi y Sugeno con 4 reglas, que aplica el criterio de mínimos cuadrados a cada regla para determinar los parámetros de las consecuencias y clustering difuso para los parámetros de las premisas. En la sección 5.5 se plantean las etapas necesarias para utilizar el modelo para realizar predicción en horizontes mayores a un paso, lo que es necesario para su utilización en el sistema de gestión de demanda de una micro-red inteligente.

Además, en este capítulo se trataron diversas formas de analizar la estabilidad de sistemas difusos de Takagi y Sugeno. Los métodos revisados se basan principalmente en la estabilidad de Lyapunov y en las desigualdades lineales de matrices (LMI). En los teoremas revisados, no influyen los pesos que van cambiando a medida que se activan las reglas, por lo que el análisis de estabilidad se realiza independiente de las entradas.

El análisis de estabilidad se agregó a las etapas de identificación del modelo. Para la nueva etapa, se eligió el teorema que se basa en el estudio de la estabilidad de las matrices de estado del sistema y de las matrices que resultan de multiplicarlas en forma cruzada. Se desarrolló una metodología para realizar este análisis, la cual se implementó en Matlab (Anexo E), para poder analizar la estabilidad del sistema difuso construido.

Se analizó la estabilidad de los sistemas candidatos, en donde se obtuvo que el sistema de 4 reglas es el único estable, por lo tanto, es el que se utiliza para realizar las predicciones de demanda eléctrica. Finalmente, con este modelo se realizaron predicciones que se utilizaron el simulador del optimizador del sistema de gestión de demanda y se compararon con una simulación que ocupaba predicciones realizadas anteriormente. La nueva predicción obtenida presenta un error de un 11% menor con respecto a la original, mejora que se refleja en los costos operacionales, los cuales disminuyen 15% para optimización a dos días.

En la siguiente sección se presenta la metodología para realizar predicción a j pasos, utilizando los modelos difusos de Takagi y Sugeno. Esta metodología es la utilizada para realizar la predicción a un horizonte de 2 días (192 pasos), la cual será utilizada por el optimizador para realizar el despacho de las unidades de la micro-red.

5.5 Predicción a j-pasos

El modelo obtenido puede utilizarse para realizar predicción a j pasos, es decir, utilizando los datos de un día se puede predecir no solo un paso hacia adelante (15 minutos), sino que múltiples pasos adelante, por ejemplo 2 días hacia adelante (192 pasos). En la Figura 27 se observan los pasos a seguir para realizar este tipo de predicción, los cuales se detallan a continuación.

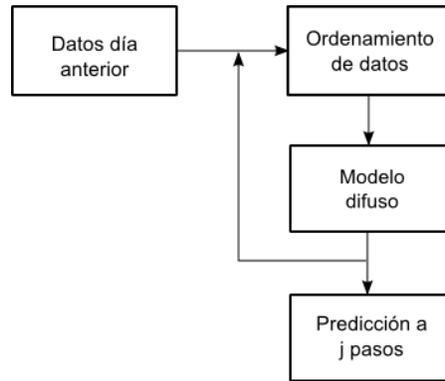


Figura 27: Diagrama módulo de predicción a j pasos

Datos día anterior: La predicción para $t + j$ será función de las predicciones del día anterior, como se ve en la siguiente ecuación:

$$\hat{y}(t + j) = F[\hat{y}(t + j - 1). \dots \hat{y}(t + j - 96)] \quad (32)$$

En donde 96 representa la cantidad de datos de un día dividido en pasos de 15 minutos.

Ordenamiento de datos: Utilizando el modelo difuso desarrollado, para realizar la predicción a j-pasos se le entregan al sistema los datos de consumo del día anterior, ordenados en un vector de la siguiente forma:

$$[y(t - 1) \ y(t - 2). \dots \ y(t - 96)] \quad (33)$$

Modelo difuso: Luego de ordenados los datos, se aplican las reglas difusas y se obtiene la salida $\hat{y}(t)$.

Iteración: Para calcular el siguiente paso ($y(t + 1)$) se ingresa la predicción realizada a los datos de entrada, ejecutando nuevamente el ordenamiento de datos, incluyendo esta vez el dato predicho, quedando el vector de datos de entrada de la siguiente forma:

$$[\hat{y}(t) \ y(t - 1) \ y(t - 2). \dots \ y(t - 95)] \quad (34)$$

Esto se repite hasta tener las j predicciones.

$$[\hat{y}(t+j) \dots \hat{y}(t+1) \hat{y}(t)] \quad (35)$$

Al ir sucesivamente agregando a los datos de entrada las predicciones realizadas en el instante anterior, se van agregando al error propio del modelo, los errores de las predicciones anteriores, por lo que el error aumenta. Por ende es de esperar que el error aumente en proporción a los pasos de predicción, siendo el modelo más confiable dentro de los primeros pasos. En el gráfico de la Figura 28 se tiene el RMSE en función del número de pasos para el cual se realiza la predicción, en donde el mínimo está para los pronósticos cuyos horizontes de predicción tienen solo un paso, lo que era de esperar ya que se utilizan prácticamente sólo datos medidos para hacer la predicción y una proporción mínima de datos estimados, también se observa una disminución del error al completar un día de predicción (96 y 192 pasos), debido a que el modelo utiliza un número entero de día como datos y en estos dos casos de mínimos locales se está prediciendo a un múltiplo del día completo.

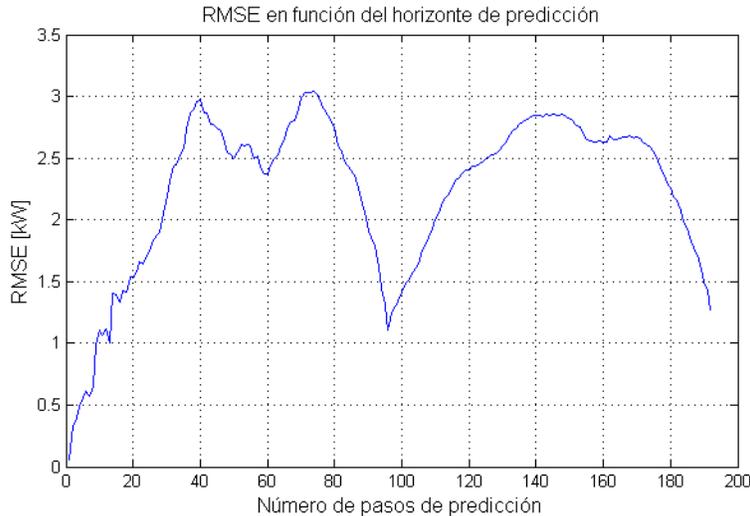


Figura 28: RMSE para predicción a J pasos en micro-red de Huatacondo

Para analizar el desempeño del sistema de predicción, se realizó la predicción a 192, 96 y 4 pasos (2 días, 1 día y 1 hora, respectivamente) sobre todos los datos disponibles, realizando la predicción cada 15 minutos y calculando el RMSE y el MAPE (Mean Absolute Percentage Error). El índice MAPE expresa la precisión del modelo de manera porcentual y se calcula utilizando la siguiente fórmula:

$$MAPE = \frac{100}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (36)$$

Este análisis se realizó utilizando un modelo entrenado una única vez, esto con los 90 primeros días del set de datos, y las predicciones se realizaron para los días siguientes utilizando la técnica

de horizonte deslizante, esto es, se realizaron predicciones a j días, luego se avanza un paso y se realiza la nueva predicción a j días con datos conocidos. Más adelante se verá el caso en donde el modelo se vuelve a actualizar a medida que transcurren los días.

Los resultados de esta prueba se pueden observar en los gráficos de la Figura 29, Figura 30 y Figura 31. En la Tabla 7 se tiene el RMSE y MAPE promedio para los tres casos, en donde, como era de esperar, se tiene un menor RMSE para las predicciones a 4 pasos ya que, como se explicó anteriormente, en ese caso el error agregado de las predicciones anteriores es menor. El índice MAPE para los cuatro casos no cambia considerablemente. Se aprecia que el error a 192 pasos es mayor que el que se observa en la Tabla 7, esto debido a que en dicha tabla sólo se utiliza un día de datos para predecir y se comparan las predicciones de 1 a 192 acumuladas, las que se comparan con los dos días siguientes completos, por lo tanto el error promediado es menor. En cambio, para la Tabla 7 se utiliza todo el conjunto de validación y se calcula el error de las predicciones sólo para el horizonte determinado (4, 96 y 192 pasos).

Tabla 7: RMSE Promedio

Pasos de predicción	RMSE promedio [kW]	MAPE promedio [%]
4	1.4460	14.0836
96	1.6746	14.2707
192	1.7039	14.7142

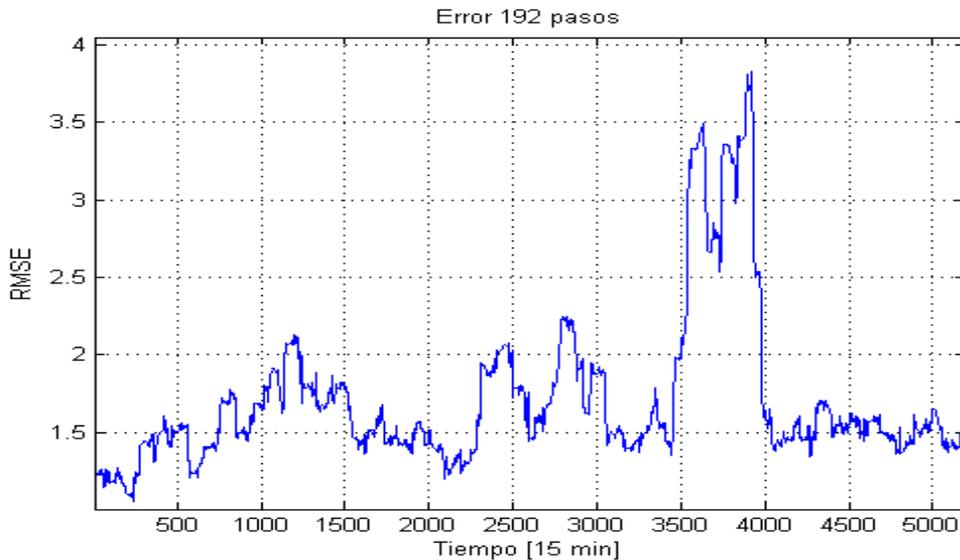


Figura 29: Error de predicción para 192 pasos

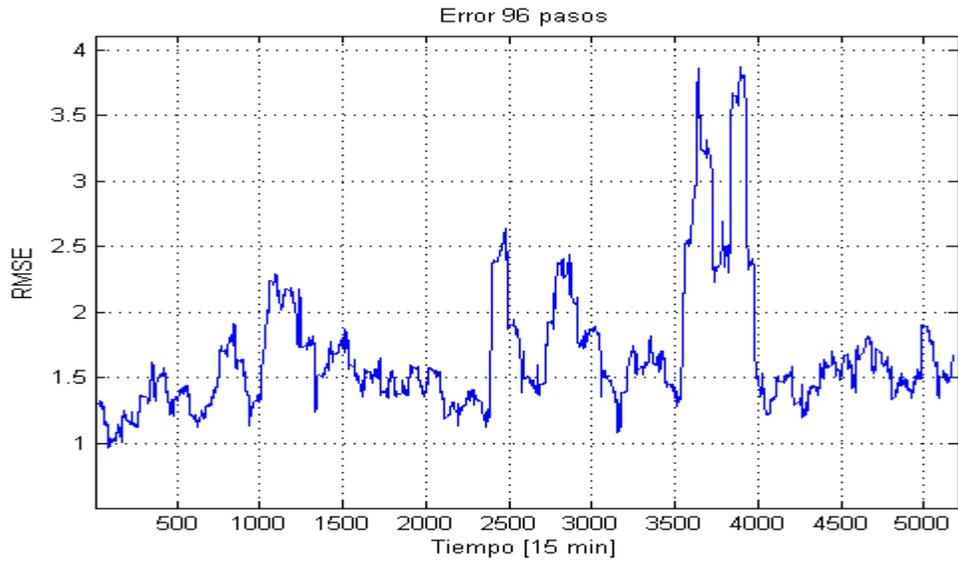


Figura 30: Error de predicción para 96 pasos

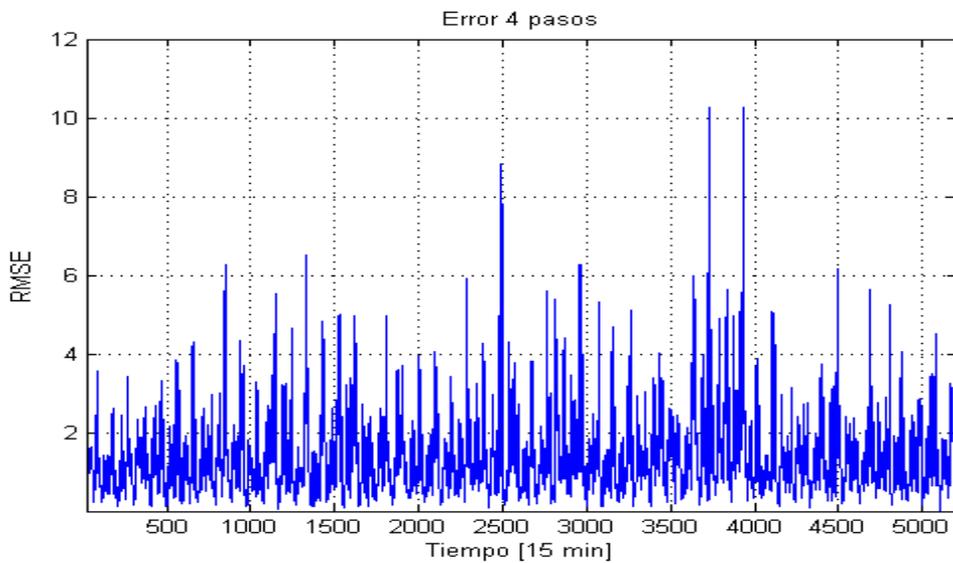


Figura 31: Error de predicción para 4 pasos

Se puede observar que entre los pasos 3500 y 4000 (día 36 y 41) el RMSE aumenta considerablemente, esto se debe a que la demanda en ese intervalo tiene un comportamiento distinto al comportamiento que tiene en el conjunto de entrenamiento, como se puede observar en el gráfico de la Figura 32, en donde se compara el promedio de los 90 días utilizados para entrenar el modelo, con uno de los días perteneciente al conjunto que presente un alto error.

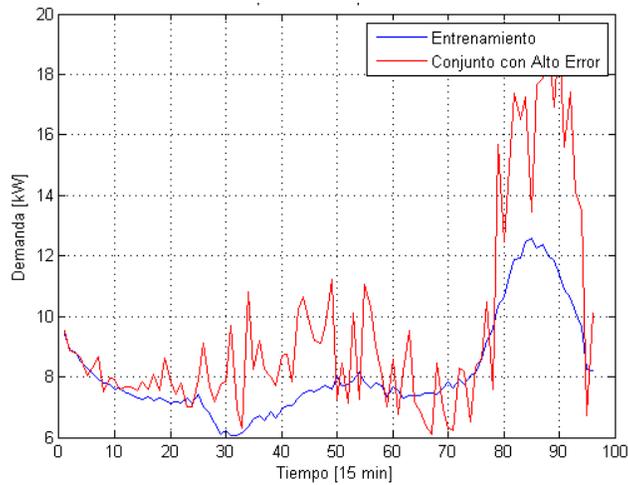


Figura 32: Comparación entre conjunto de entrenamiento y día perteneciente al conjunto con alto error (21-Abril)

Tomando en cuenta que, el error aumenta considerablemente si se tienen días con una demanda cuyo comportamiento difiere considerablemente del que se tiene en el conjunto de entrenamiento, se estudia volver a entrenar el modelo cada cierta cantidad de días. En este caso se contaba con un conjunto limitado de datos por lo que al aumentar el número de datos utilizados para entrenar, disminuía el conjunto de validación. Se probaron para los horizontes de predicción de 192, 96 y 4 pasos, modelos entrenados con 30, 60 y 90 días, los cuales se entrenaron en cada caso cada 7, 15 y 30 días. Los resultados, en cuanto al cálculo del RMSE promedio para cada caso, se puede observar en la siguiente tabla.

Tabla 8: RMSE para modelo entrenado 7, 15 o 30 días

Horizonte de Predicción	RMSE promedio [kW]			
	Modelo Entrenado con:	Frecuencia de entrenamiento		
		7 Días	15 Días	30 Días
192 Pasos	30 Días	1.7947	1.7846	1.7978
	60 Días	1.7761	1.7653	1.7781
	90 Días	1.6956	1.6959	1.7051
96 Pasos	30 Días	1.7210	1.7195	1.7288
	60 Días	1.6837	1.6798	1.7034
	90 Días	1.6564	1.6560	1.6713
4 Pasos	30 Días	1.4447	1.4453	1.4795
	60 Días	1.4234	1.4249	1.4390
	90 Días	1.4256	1.4243	1.4291

Tabla 9: MAPE para modelos entrenados cada 7, 15 o 30 días

Horizonte de Predicción	MAPE promedio [%]			
	Modelo Entrenado con:	Frecuencia de entrenamiento		
		7 Días	15 Días	30 Días
192 Pasos	30 Días	15.9003	15.6955	16.1343
	60 Días	15.5700	15.4568	15.5245
	90 Días	14.1630	14.1987	14.2569
96 Pasos	30 Días	15.5260	15.2391	15.6270
	60 Días	15.2763	15.2345	15.2777
	90 Días	13.9682	13.9801	14.0975
4 Pasos	30 Días	15.5171	15.6394	16.2135
	60 Días	15.4031	15.4151	15.4399
	90 Días	14.4017	14.3877	14.5323

Para este caso la mayor disminución en el error se tiene al aumentar la cantidad de datos con los que se entrena el modelo. No se nota una diferencia sustancial al aumentar la frecuencia de entrenamiento, por lo que es mejor enfocarse en utilizar una gran cantidad de datos para entrenar el modelo que en entrenarlo con mayor frecuencia.

Hay que tener en cuenta que al tener datos limitados y entrenar con 90 días el conjunto de validación es menor lo que afecta los resultados, por lo tanto se propone volver a realizar este estudio con los datos de todo un año para analizar el efecto de las estaciones del año.

5.5.1 Discusión

Se realizaron pronósticos de demanda hasta 192 pasos, es decir, 2 días para el caso de estudio, obteniéndose RMSE bajo 2 [kW] (17%) para pronósticos realizados para distintas fechas utilizando el mismo modelo. También se estudió el comportamiento de los modelos para diferentes horizontes, notándose que el mínimo error se obtiene para los horizontes de predicción con menos pasos, lo que era de esperar por utilizar una mayor proporción de datos reales, que no acumulan error de datos predichos. Se observó además, que al completar un múltiplo entero de días el error disminuye considerablemente.

Para analizar la frecuencia adecuada de entrenamiento se utilizó una cantidad limitada de datos por lo que sólo se probó entrenar con una frecuencia entre 7 y 30 días. Esto no entregó un resultado concluyente en cuanto a la frecuencia de entrenamiento, por lo tanto se propone que el estudio se extienda con los datos de todo un año, de manera de poder determinar cada cuanto tiempo debe entrenarse un nuevo modelo para poder mantener el buen desempeño del predictor, debido a que factores como las estaciones del año pueden influir en el comportamiento de los consumidores.

En la siguiente sección se realiza un análisis comparativo entre el bloque desarrollado y uno realizado con redes neuronales en un trabajo anterior, también relacionado con el EMS.

5.6 Análisis comparativo

Se comparó el desempeño del bloque de predicción realizado en este trabajo, con las predicciones resultantes del uso de redes neuronales en [89]. La red neuronal diseñada consta de 3 capas, una capa oculta, 96 neuronas en la capa de entrada, 8 neuronas en la capa oculta, una neurona en la capa de salida, utiliza las funciones ‘Tansig’ para activar la capa oculta y ‘Purelin’ para activar la capa de salida, además usa el método de backpropagation para el entrenamiento.

La comparación se realizó por medio de los índices RMSE y MAPE, para horizontes de predicción de 1 hora (4 pasos), 1 día (96 pasos) y 2 días (192 pasos), utilizando horizonte deslizante sobre el conjunto de validación. Es decir, se realiza la predicción a N pasos, para la cual se calcula RMSE y MAPE, luego se avanza un paso y con datos reales y se vuelve a realizar el procedimiento, obteniéndose finalmente dos conjuntos con los valores de RMSE y MAPE calculados en cada predicción realizada.

Los datos utilizados consisten en un conjunto de datos de 14976 registros de demanda. De los cuales un 40% se utilizó para entrenar, un 40% como conjunto de prueba y un 20% para validar. Al realizar un pre-procesamiento de los datos se notó la falta del registro de algunos días, lo que es de importancia al estar trabajando con un modelo que se basa en los datos de días pasados. La comparación se realizó utilizando este conjunto de datos, ya que fue el utilizado para las pruebas de la red neuronal, omitiendo la falta de dichos días. Los promedios de RMSE y MAPE obtenidos de las predicciones se encuentran en la Tabla 10 y Tabla 11, de donde se observa que se obtiene un mejor comportamiento, para los tres horizontes, utilizando el modelo difuso.

Tabla 10: Comparación con red neuronal utilizando RMSE.

RMSE promedio [kW]					
192 pasos (48 hrs)		96 pasos (24 hrs)		4 pasos (1 hora)	
TKS	Red Neuronal	TKS	Red Neuronal	TKS	Red Neuronal
1.71	1.72	1.54	1.80	1.53	1.65

Tabla 11: Comparación con red neuronal utilizando MAPE.

MAPE promedio[%]					
192 pasos (48 hrs)		96 pasos (24 hrs)		4 pasos (1 hora)	
TKS	Red Neuronal	TKS	Red Neuronal	TKS	Red Neuronal
14.83	15.98	12.80	15.47	13.37	14.12

5.6.1 Discusión

El modelo de predicción de demanda eléctrica basado en el modelo difuso de Takagi y Sugeno, fue comparado con un modelo de predicción basado en redes neuronales, el cual fue desarrollado para la misma micro-red. La comparación se realizó utilizando el mismo set de datos y proporción para los conjuntos de entrenamiento, prueba y validación. El resultado fue una mejora en las predicciones de hasta un 14%, para 96 pasos de predicción, utilizando la técnica de horizonte deslizante.

Finalmente, se tiene que el modelo difuso presenta un mejor rendimiento al hacer predicción para distintos horizontes, por lo que se propone implementarlo directamente en la micro-red para ser utilizado en línea.

5.7 Conclusiones del capítulo

En el presente capítulo se desarrolló un módulo de predicción de demanda para micro-redes, el cual incluye una etapa de análisis de estabilidad para asegurar su buen comportamiento en el tiempo. Este módulo se basa en modelación difusa de Takagi y Sugeno, por lo que inicialmente se realizó una revisión teórica de estos modelos y sus etapas típicas de identificación, para luego describir el desarrollo del modelo utilizando estas mismas etapas y agregando el análisis de estabilidad. Se detalla también como se llegó a elegir el modelo TKS21 con 4 reglas y 96 regresores, el cual además de presentar el menor error, también es estable.

Ademas de esto, también se detalló la metodología para realizar predicción a j-pasos, para usar el modelo a 96 pasos, lo que es utilizado por el optimizador, y así genéricamente poder utilizar esta metodología a cualquier horizonte genérico.

Los resultados obtenidos se compararon en el optimizador con los originalmente utilizados, obteniéndose menores costos al tener una predicción más acertada. También se compararon con las predicciones basadas en redes neuronal, de donde se obtuvieron también mejores en cuanto a error cuadrático.

6 Gestión de demanda

En el presente capítulo, se proponen dos metodologías para mejorar el sistema de gestión de energía de micro-redes inteligentes. Estas metodologías están enfocadas a la gestión de demanda considerando la técnica de respuesta de la demanda, la cual consiste en enviar señales a los consumidores para que modifiquen su perfil de consumo de acuerdo a las necesidades de la red. La primera metodología propuesta, consiste en la utilización de intervalos difusos para conocer el rango de desplazamiento dinámico para la carga, a partir de datos históricos de demanda. La segunda, consiste en realizar mejoras a la predicción de demanda, que el EMS utiliza para la optimización, considerando que las señales de gestión de demanda, que se envían a los consumidores, hacen que éstos modifiquen su patrón de consumo afectando así la predicción, para lo cual se plantea modelar la variación del consumo utilizando modelación difusa de Mamdani.

A continuación se detalla el método para determinar el rango de desplazamiento dinámico de carga, para la cual se comienza explicando para qué se utiliza este rango de desplazamiento, luego se trata el concepto de intervalo difuso y dos métodos propuestos para realizar la predicción de estos intervalos en un horizonte determinado de tiempo. Finalmente se realiza el cálculo de dos intervalos utilizando distintos ancho para estos y se probaron ambos en el simulador del optimizador de la micro-red, para luego compararlos con el caso sin desplazamiento de demanda y el caso de rango de desplazamiento estático.

6.1 Metodología propuesta para determinar el rango de desplazamiento dinámico de carga, utilizando intervalos difusos

El rango de desplazamiento de carga es utilizado por el optimizador del sistema de gestión de demanda, para determinar el factor de desplazamiento de carga necesario para tener un despacho óptimo de las unidades, es decir, determinar cuánto debe aumentar o disminuir el consumo eléctrico de la comunidad. Actualmente este factor corresponde a una entrada fijada manualmente, en esta sección se propone una metodología para determinar este rango de desplazamiento de carga, a partir de datos históricos de demanda, utilizando para esto intervalos difusos. Por lo tanto, se plantea modificar la estructura del sistema de gestión de energía presentado en la Figura 3, para incorporar intervalos difusos y dejar también como entrada dinámica el rango de desplazamiento de carga, el cual se alimenta de datos históricos de ella, como puede observarse en el esquema de la Figura 33, para luego ser una entrada al optimizador, entregando el rango del desplazamiento.

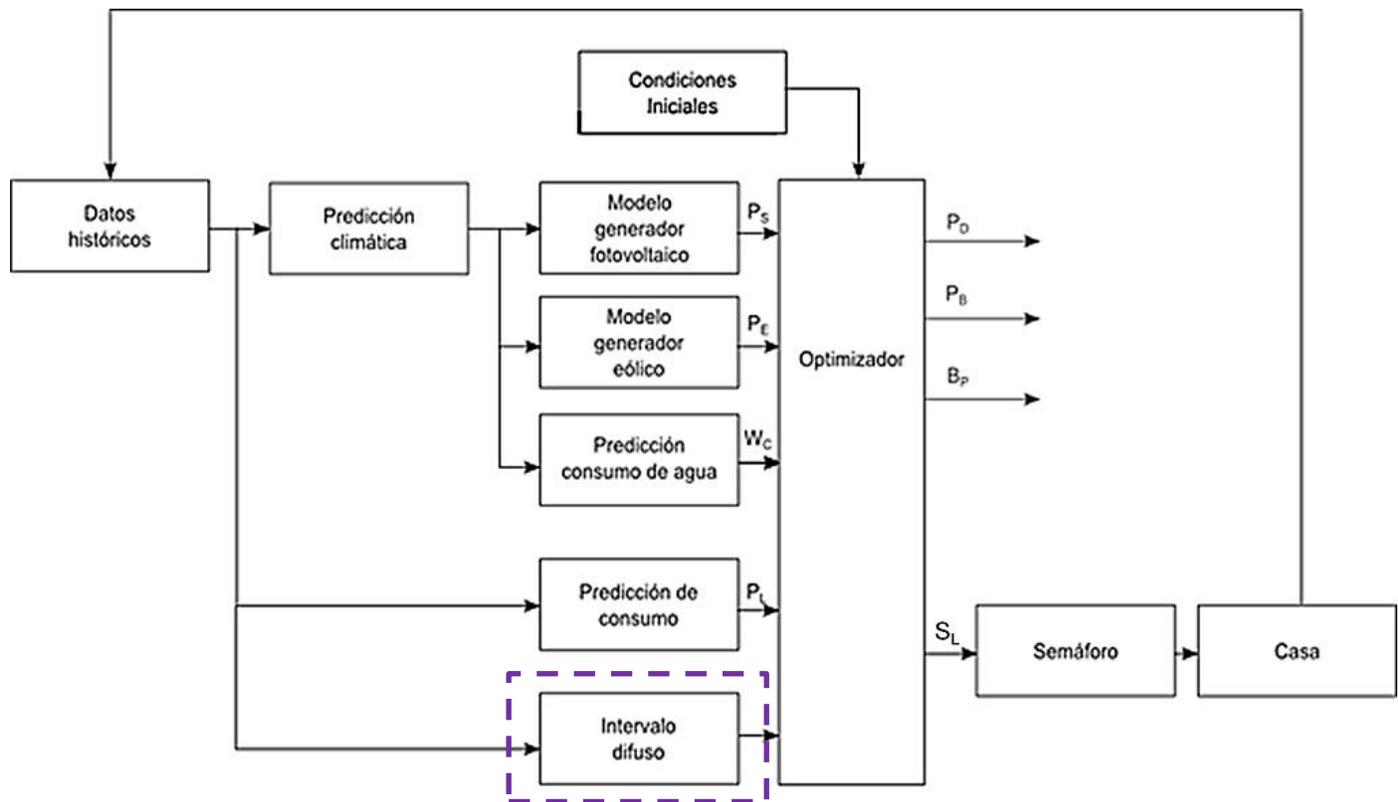


Figura 33: EMS integrando intervalo difuso

El factor de desplazamiento de carga es calculado por el optimizador, dentro de un rango que se establece previamente, el cual refleja hasta cuánto puede desplazarse la demanda en cada intervalo de tiempo. En este trabajo se propone establecer este rango dinámicamente, utilizando intervalos difusos, a partir de datos históricos, por lo que expresará, con un cierto nivel de confianza, cuánto se puede desplazar la demanda en el futuro, tomando en cuenta cuánto se ha desplazado en el pasado.

6.1.1 Intervalos difusos

El problema de aproximar una función a partir de un conjunto finito de datos, usando como criterio de optimización minimizar el error de estimación, ha recibido una gran atención. En [90] se introduce el concepto de modelo de intervalo difuso, para ser utilizado en detección de falla, el cual corresponde a un modelo difuso con parámetros superiores e inferiores que contiene todos los valores medidos, utilizando programación lineal y el enfoque de los modelos de Takagi y Sugeno.

Entonces, la idea de la modelación del intervalo de confianza difuso es encontrar una función difusa superior \bar{f} y una función difusa inferior \underline{f} , tal que se satisfaga:

$$\underline{f}(z_i) \leq g(z_i) \leq \bar{f}(z_i) \quad (37)$$

En donde $z_i \in Z$ es un conjunto de entradas e $Y = \{y_1, \dots, y_n\}$ corresponde a los valores medidos de la salida y se tiene $y_i = g(z_i)$, $i = 1, \dots, n$, el cual corresponde al conjunto de validación, es decir, se busca que el intervalo difuso contenga a los datos de validación. El principal requerimiento al definir la banda del intervalo es que sea lo mas estrecha posible y que contenga un cierto porcentaje de datos, llamado nivel de confianza [91]. En [92] se presenta una metodología para la identificación del modelo de intervalo difuso, basándose en aproximación con funciones difusas, a diferencia de la utilización de la linealización por tramos, que es lo que usualmente se utiliza. Analíticamente, las funciones superior ($\bar{f}(z_i)$) e inferior ($\underline{f}(z_i)$) pueden encontrarse al resolver el siguiente problema de optimización:

$$\min_{\bar{f}} \max_{z_i \in Z} |y_i - \bar{f}(z_i)| \quad \text{sujeto a } y_i - \bar{f}(z_i) \leq 0 \quad (38)$$

$$\min_{\underline{f}} \max_{z_i \in Z} |y_i - \underline{f}(z_i)| \quad \text{sujeto a } y_i - \underline{f}(z_i) \geq 0 \quad (39)$$

La covarianza esperada, de la diferencia entre los datos observados y la salida del modelo esta dada por:

$$\Delta \hat{y}_j = \text{cov}(y_j - \hat{y}_j) = \hat{\sigma}_j^2 \mathbf{I} + \hat{\sigma}_j^2 \xi_j^T (\xi_j \xi_j^T)^{-1} \xi_j \quad (40)$$

Con \hat{y}_j la salida del modelo local j . La varianza del ruido local es $E\{e_j e_j^T\} = \hat{\sigma}_j^2 \mathbf{I}$

Para un conjunto de datos, los intervalos de confianza superior e inferior para el modelo local j están definidos respectivamente como:

$$\underline{f}_j(m_i) = \theta_{i,j}^T \xi_j - \alpha \Delta \hat{y}_{i,j} \quad (41)$$

$$\bar{f}_j(m_i) = \theta_{i,j}^T \xi_j + \alpha \Delta \hat{y}_{i,j} \quad (42)$$

Con $\Delta\hat{y}_{i,j} = \hat{\sigma}_j \left(1 + \varepsilon_{i,j}^T (\xi_j \xi_j^T)^{-1} \xi_{i,j}\right)^{1/2}$ para $i = 1, \dots, N$. El parámetro α debe ser sintonizado dependiendo de la cantidad de datos se quiera tener dentro de la banda. Luego, el intervalo superior e inferior queda representado como sigue:

$$\overline{\hat{y}}_t = f^{TS}(x_{t-1}^p, y_{t-1}, u_{t-1}) - \alpha I^{TS}(x_{t-1}^p, y_{t-1}, u_{t-1}) \quad (43)$$

$$\underline{\hat{y}}_t = f^{TS}(x_{t-1}^p, y_{t-1}, u_{t-1}) + \alpha I^{TS}(x_{t-1}^p, y_{t-1}, u_{t-1}) \quad (44)$$

Siendo el intervalo difuso de confianza:

$$I^{TS}(x_{t-1}^p, y_{t-1}, u_{t-1}) = \sum_{j=1}^m \beta_j(x_{t-1}^p) \Delta\hat{y}_{tj} \quad (45)$$

En donde x_{t-1}^p corresponde a las entradas pasadas, y_{t-1} a las salidas pasadas y u_{t-1} a las acciones de control aplicadas en $t - 1$, las cuales no son consideradas para efectos de las predicciones realizadas en este trabajo.

Dado que el optimizador trabaja con un horizonte de predicción de 2 días, es necesario calcular el rango de desplazamiento para este horizonte. En la siguiente sección se detallan dos metodologías para calcular intervalo difuso para horizontes de predicción de j pasos.

6.1.2 Intervalo difuso a j pasos

Para el optimizador se necesitan los rangos calculados para un horizonte de dos días. A continuación, se proponen dos métodos para realizar predicción del intervalo, de manera genérica, a j pasos, para luego aplicar esto al horizonte de 192 pasos (dos días).

Método A

En este primero método, la predicción del intervalo para el paso j se realiza utilizando la demanda predicha hasta el paso $j-1$, es decir el intervalo del paso siguiente es función de la demanda predicha para el paso anterior, como se muestra en la ecuación 41. Gráficamente se observa éste método en la Figura 34, si se tienen los datos reales hasta k se realiza la predicción de demanda para $k + 1$ y se calcula el intervalo para el dato $\hat{y}(k + 1)$, luego, incluyendo esta demanda predicha al conjunto de datos de demanda original, se realiza la predicción para $k + 2$ y se calcula el intervalo para $\hat{y}(k + 2)$. Este procedimiento se lleva a cabo hasta llegar a $k + j$. Para cada horizonte de predicción se utiliza el α ya sintonizado para dicho horizonte.

$$\hat{I}(k+j) = F(\hat{y}(k+j-1), \hat{y}(k+j-2), \dots) \quad (46)$$

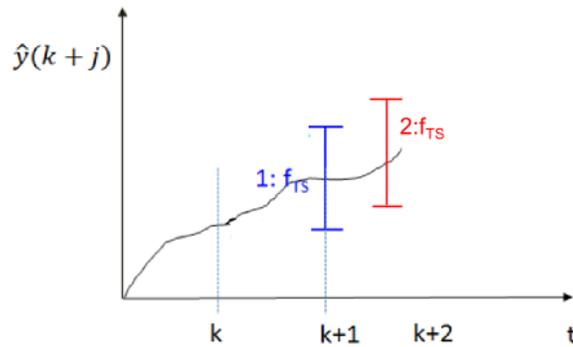


Figura 34: Método A

Método B

Este método se basa en realizar el intervalo tomando como referencia los extremos máximo y mínimo del intervalo anterior. Para esto, el primer paso es realizar predicción a un paso con el método A, obteniéndose tres valores:

$$\hat{y}(k+1/k) = f_{TS}(\cdot) \quad (47)$$

$$\bar{y}(k+1/k) = f_{TS}(\cdot) + \alpha(k)I(\cdot) \quad (48)$$

$$\underline{y}(k+1/k) = f_{TS}(\cdot) - \alpha(k)I(\cdot) \quad (49)$$

Luego, para el siguiente paso se generan dos intervalos, uno entorno a $\bar{y}(k+1/k)$ y el otro entorno a $\underline{y}(k+1/k)$, obteniéndose así dos intervalos, denominados Modelo 1 y Modelo 2 en la Figura 35. De estos dos intervalos se tomará el máximo de la cota superior de ambos modelos como $\bar{y}(k+2/k)$ y el mínimo de ambas cotas inferiores como $\underline{y}(k+2/k)$, obteniéndose el intervalo 1' que se muestra en la Figura 35, luego, a partir de estas dos nuevas cotas se repite el proceso las veces que se requiera.

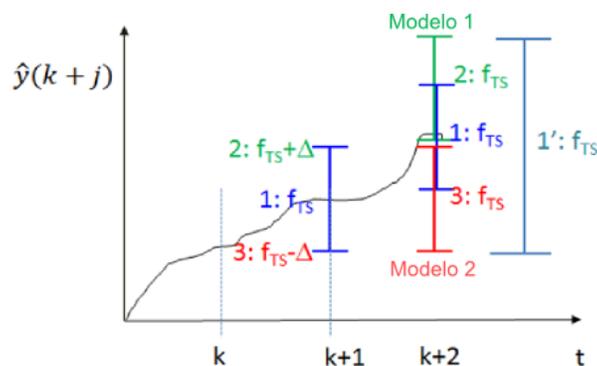


Figura 35: Método B

Por lo tanto, se tendrán dos intervalos difusos, el primero dependerá del máximo de las dos cotas superiores generadas por ambos modelos en el paso anterior, y el segundo dependerá del mínimo de las cotas inferiores generadas también por ambos modelos en el paso anterior, como se representa en las ecuaciones 50 y 51.

$$\widehat{I}_1(k+j) = F(\text{Max}(\overline{y}_1(k+j-1), \overline{y}_2(k+j-2)), \dots) \quad (50)$$

$$\widehat{I}_2(k+j) = F(\text{Min}(\underline{y}_1(k+j-1), \underline{y}_2(k+j-2)), \dots) \quad (51)$$

Con \widehat{I}_1 e \widehat{I}_2 , los intervalos generados con el modelo B, para la cota superior e inferior. Como en este caso se tienen dos intervalos distintos, uno para la cota superior y uno para la inferior, el intervalo de confianza difuso resultante no será simétrico con respecto a la predicción de demanda, como pasaba para el Método A.

A continuación se detalla el proceso para sintonizar el parámetro α , dependiendo del nivel de confianza se requiera para el intervalo.

Sintonización

El proceso de sintonización es el mismo para los dos métodos planteados. Se realiza la predicción a j pasos sobre todo el conjunto de entrenamiento, y se ajusta el parámetro α para obtener un nivel de confianza sobre el 95%, el cual representa cuántos datos medidos están efectivamente dentro del intervalo difuso modelado. Esto es, se fija un α inicial con el cual se calcula el intervalo a j pasos para todo el conjunto, con el intervalo calculado se obtiene el nivel de confianza, si éste es menor al 95% entonces se aumenta levemente el parámetro α y se realiza nuevamente la predicción del intervalo a j pasos. Este nivel de confianza se calcula como sigue:

$$Cl = 1 - \frac{\sum_{i=1}^M \delta_i}{M} \quad (52)$$

Donde M es el número de registros en el conjunto de datos y δ_i es una variable binaria que indica si el dato i pertenece o no al intervalo. En la Figura 36 y Figura 37, se tienen los gráficos que muestran el parámetro α para los métodos A y B respectivamente, en función de los pasos de predicción. Se observa que para el método A el parámetro es prácticamente constante entre los valores para distintos pasos de predicción. Esto era de esperar, ya que los intervalos futuros se hacen a partir de predicción de demanda pasada, por lo tanto se mantienen acotados y como la demanda a través de los días sigue un patrón similar, entonces para predicciones a distintos horizontes de tiempo, el parámetro α que satisface un intervalo de confianza del 95% no cambia de manera notoria. Por otro lado, para el método B se observa que el parámetro α disminuye abruptamente al iniciarse el aumento de pasos de predicción y que luego se mantiene prácticamente estable. Esta abrupta disminución se debe a que se están utilizando los extremos del intervalo anterior para predecir el intervalo siguiente, por lo tanto el intervalo tiende a ensancharse a medida que se aumenta la cantidad de pasos de predicción, por lo tanto se necesita

un menor α para tener un nivel de confianza del 95%. El leve aumento final en este caso puede deberse a errores numéricos del software.

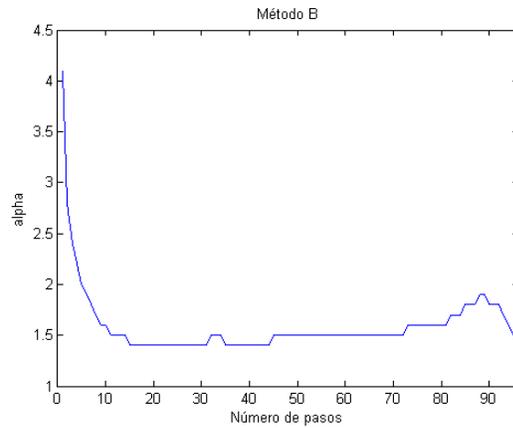
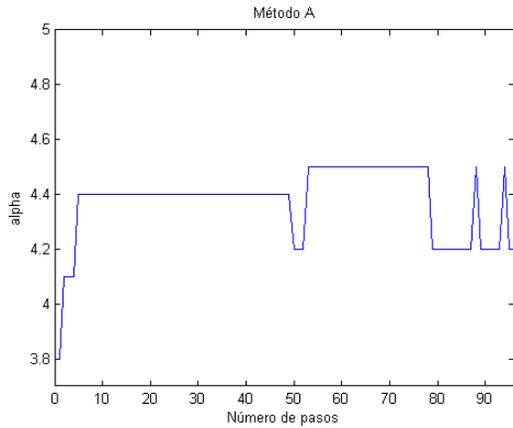


Figura 36: Parámetros alpha para método A **Figura 37: Parámetros alpha para método B**

El método elegido para calcular el rango dinámico para el factor de desplazamiento de carga a 192 pasos es el A, ya que se mantiene acotado a diferencia del método B, en el cual comienza a diverger por la forma en que está diseñado. En la Figura 38 se observan los intervalos con distintos parámetros α , sintonizados cada uno para obtener niveles de confían entre 10% y 90%, utilizando el método A, para predicción a 192 pasos.

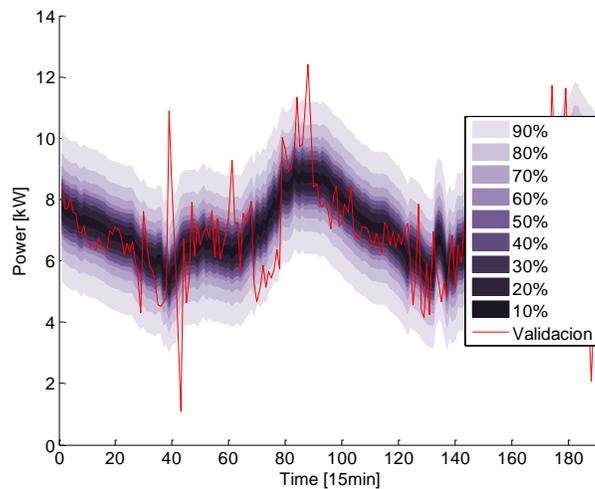


Figura 38: Intervalo difuso con distintos niveles de confianza para un horizonte de 192 pasos

A continuación se presenta el cálculo de este rango y los resultados obtenidos al utilizarlo en el optimizador de la micro-red.

6.1.3 Cálculo del rango para factor de desplazamiento de carga

El rango de desplazamiento se calcula en este caso utilizando el modelo de Takagi y Sugeno, que se presenta en la sección 5 para predicción de demanda, el cual, a grandes rasgos, cuenta con cuatro reglas y 96 regresores, es decir, toma en cuenta la información de un día pasado para modelar la predicción futura. Como este rango está diseñado para ser utilizado en el sistema de gestión de demanda de la micro-red instalada en Huatacondo, se realiza la predicción de este a 192 pasos, utilizando en este caso el Método A, presentado en la sección anterior. Dado que el rango de desplazamiento se expresa como una proporción de la demanda, para extraerlo a partir del intervalo, se procede a realizar la predicción del intervalo a 192 pasos y además la predicción de demanda para el mismo horizonte, con lo que se obtienen tres datos para cada paso temporal: la predicción de demanda, una cota superior de ésta y también una cota inferior. Utilizando estos tres datos se calcula el rango de desplazamiento máximo y mínimo como se presenta en las siguientes ecuaciones:

$$S_{Lmax}(t) = 1 + \frac{abs(\hat{y}(t) - \bar{y}(t))}{\hat{y}(t)} \quad (53)$$

$$S_{Lmin}(t) = 1 - \frac{abs(\hat{y}(t) - \underline{y}(t))}{\hat{y}(t)} \quad (54)$$

En donde $\hat{y}(t)$ corresponde a la predicción de demanda en el tiempo t, $\bar{y}(t)$ a la cota superior del intervalo difuso para el tiempo t, e $\underline{y}(t)$ a la cota inferior para el tiempo t. Esto se probó en el simulador del sistema de gestión de demanda, comparando con el caso en donde no se utiliza gestión de demanda, dos casos con distintos rangos. Estos dos nuevos casos se realizaron utilizando distintos parámetros α , para tener un nivel de confianza distinto en cada uno, siendo uno construido con $\alpha = 1$, lo que resulto en un nivel de confianza del 60%, y el segundo con $\alpha = 4.5$ con lo que se tiene un nivel de confianza del 97%, ambos para predicción a 192 pasos. En los gráficos de la Figura 39 y Figura 40 se presentan ambos intervalos difusos y los datos reales de demanda.

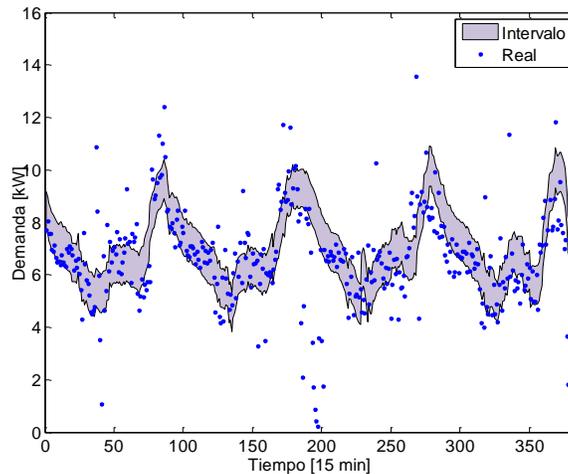


Figura 39: Intervalo realizado con a=1 (Nivel de confianza=60%)

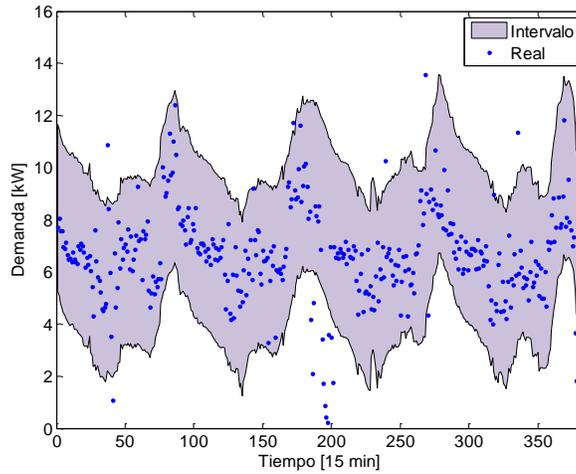


Figura 40: Intervalo realizado con $\alpha=4.5$ (Nivel de confianza =97%)

Al calcular el rango de desplazamiento utilizando estos intervalos, se tiene que para el primer intervalo, construido con $\alpha = 1$, el rango de desplazamiento llega hasta el 20% en su máximo, es decir $S_{Lmax} = 1.2$ y $S_{Lmin} = 0.8$, mientras que para el segundo intervalo, con $\alpha = 4.5$ el intervalo llega a 90% en su punto máximo ($S_{Lmax} = 1.9, S_{Lmin} = 0.1$). En el gráfico de la Figura 41, se presenta el factor de desplazamiento resultante de la optimización para el periodo de dos días, en este gráfico se puede observar que al darse un mayor rango de desplazamiento con el intervalo construido con $\alpha = 4.5$, también aumenta el factor de desplazamiento, esto debido a que se da más flexibilidad al sistema para el movimiento de las cargas.

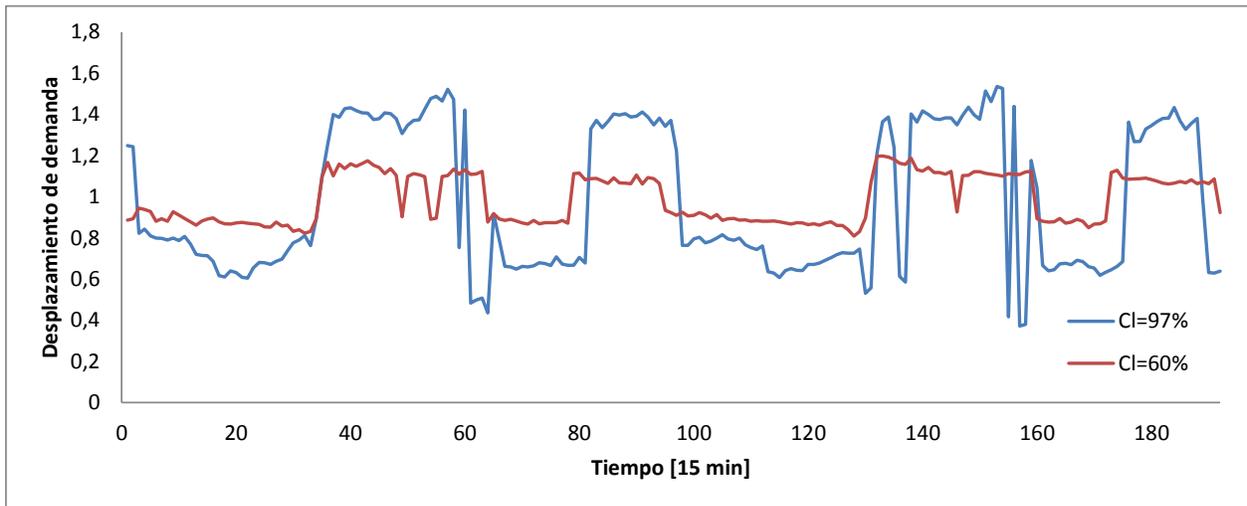


Figura 41: Rango para el factor de desplazamiento de demanda

En la Tabla 12 se presentan los resultados del simulador del sistema de gestión de demanda, en términos de costos, para los tres casos que se probaron. El primer caso corresponde al sin control

de demanda (Sin CD), es decir, no considera desplazamiento de la demanda ($S_{Lmax} = S_{Lmin} = 1$), el segundo corresponde al caso con un desplazamiento de demanda del 5% (CD=5%), es decir $S_{Lmax} = 1.05$ y $S_{Lmin} = 0.95$, el que se mantiene constante durante todo el horizonte de optimización, y los dos restantes son los que utilizan los dos rangos presentados.

Como se puede observar en la Tabla 12, los costos disminuyen a medida que el rango de desplazamiento de carga aumenta, es decir, se da mas flexibilidad al factor de desplazamiento. Esto era de esperar ya que, como el sistema de gestion de demanda esta diseñado para enviar señales a los consumidores, se supone que los consumidores modificaran su demanda según los requerimientos del optimizador, con lo que se logra optimizar el uso del combustible al aprovechar de manera más eficiente los recursos renovables, que en el caso de esta simulación corresponde a la energía solar.

Tabla 12: Costos para diferentes rangos de desplazamiento a un horizonte de 2 días

	Horizonte de 2 días			
	Estático		Dinámico	
	Sin CD	CD=5%	$\alpha=1$	$\alpha=4.5$
Costo operacional (CLP)	\$53494	\$42561	\$40753	\$39880
Costo partida (CLP)	\$4000	\$2000	\$2000	\$2000
Costo combustible (CLP)	\$57495	\$44561	\$42753	\$41880
Costo final (CLP)	\$55391	\$45387	\$44015	\$40231

Este análisis de costos no es lo único que se debe tener en cuenta, al momento de evaluar los intervalos utilizados para determinar el rango de desplazamiento, ya que estos cambios en la demanda también influyen en la vida útil de las baterías, al tener distintos ciclos de carga y descarga para los diferentes rangos de desplazamiento. Por lo tanto, se propone que en el futuro se estudie cómo influyen los cambios en el factor de desplazamiento la vida útil de las baterías.

En las figuras siguientes se presentan gráficamente los resultados obtenidos para los cuatro casos presentados. Como se puede observar, al aumentar el ancho del intervalo, disminuye el tiempo en que se utiliza el generador diésel, lo que se traduce en la disminución de costos visto en la anterior tabla. El mayor aumento en el desplazamiento de la demanda se da en las horas de luz, lo que tiene sentido ya que se está contando con energía solar para satisfacer tanto la demanda de la comunidad, como para cargar las baterías de la micro-red. El siguiente aumento en el desplazamiento corresponde al horario peak nocturno, esto se debe a que se pretende acumular el consumo eléctrico en una menor cantidad de tiempo para mantener encendido el generador diésel por periodos más cortos.

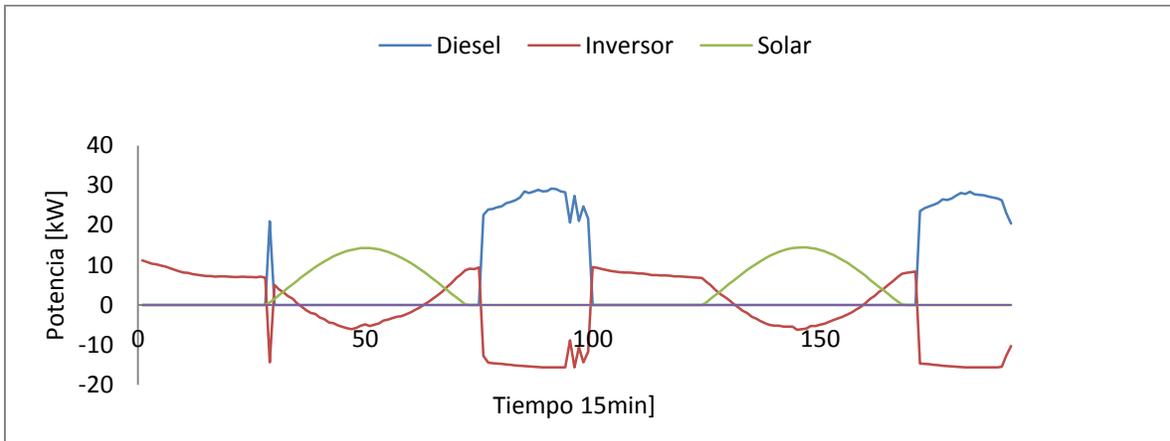


Figura 42: Unidades de la micro-red sin control de demanda

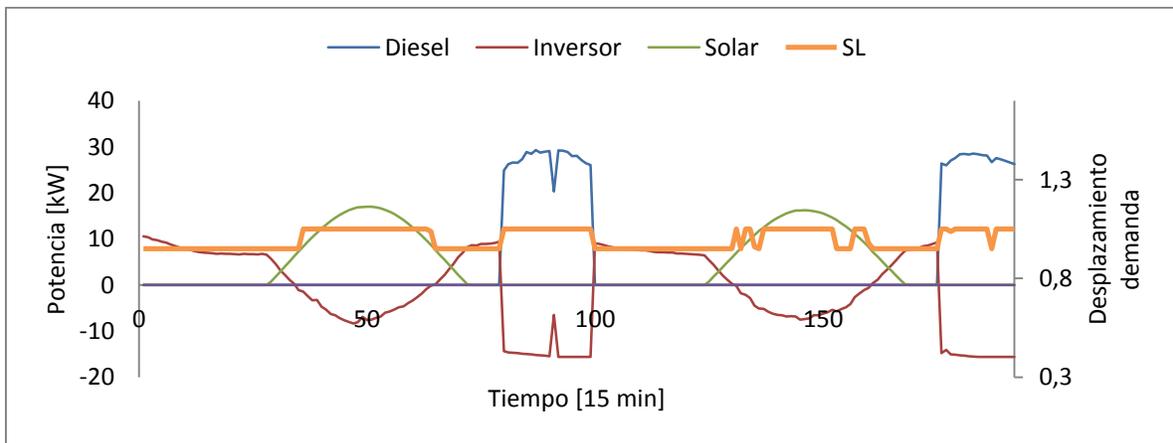


Figura 43: Unidades de la micro-red con un desplazamiento estático de demanda del 5%

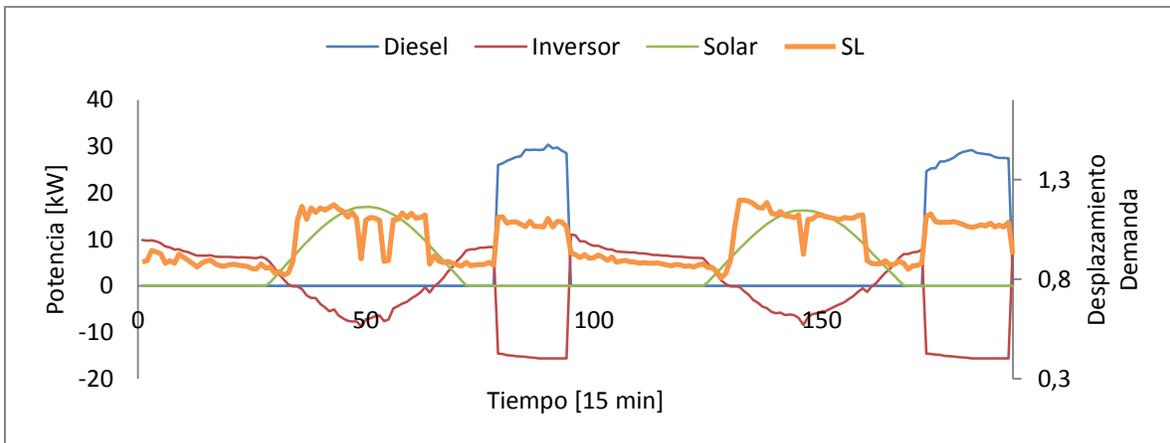


Figura 44: Unidades de la micro-red para un desplazamiento basado en el intervalo construido con $\alpha=1$

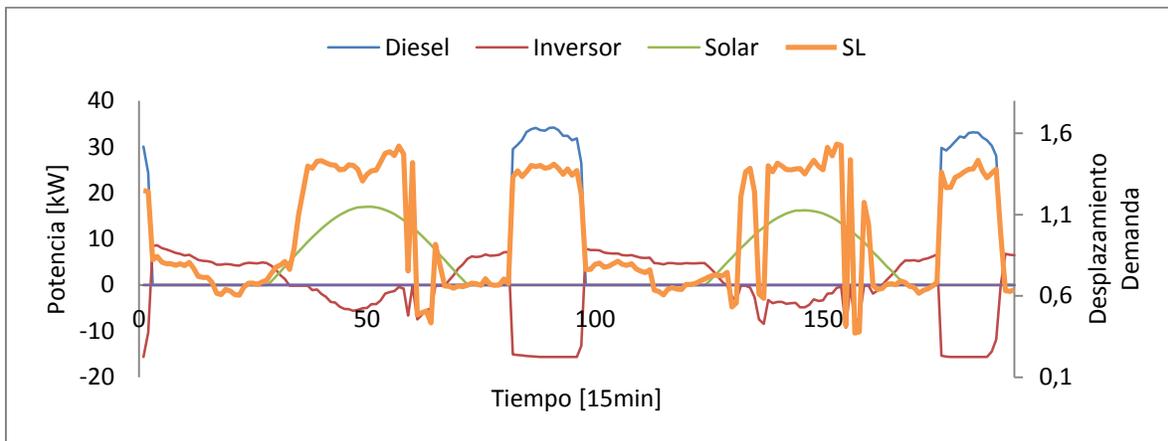


Figura 45: Unidades de la micro-red para un desplazamiento basado en el intervalo construido con $\alpha=4.5$

Se debe tener en consideración, que el simulador del optimizador asume que la demanda se desplazará lo indicado, pero esto en la realidad no sucede, ya que está en las manos de los consumidores la decisión de cuánto cambiarán su demanda. Por lo tanto, no es necesario utilizar intervalos con altos niveles de confianza ya que estos llevan a factores de desplazamientos altos que tienen menor posibilidad de ser cumplidos. En el capítulo siguiente se trata la modelación de la variación del consumo eléctrico en función de las señales de gestión de demanda.

6.1.4 Discusión

En esta sección se trató el cálculo del rango dinámico para el factor de desplazamiento, utilizando para esto intervalos difusos. Este rango da los límites al optimizador para cuánto puede desplazarse la demanda en cada bloque de tiempo, en este caso de 15 minutos. Se propuso utilizar intervalos difusos para modelar este rango de manera dinámica, tomando en cuenta la demanda histórica ya que de esta se pueden extraer los límites dentro de los cuales los consumidores tienden a desplazar su demanda.

Se plantearon 2 métodos para realizar la predicción del intervalo difuso a j pasos, de los cuales se utilizó el modelo A para modelar dos intervalos a 192 pasos con distinto nivel de confianza, a partir de los cuales se calcularon rangos de factor de desplazamiento para ser utilizados en el optimizador. Se pudo apreciar que mientras mayor es el rango para el factor de desplazamiento, menores son los costos, lo que era de esperar ya que se le da más flexibilidad al optimizador para desplazar la demanda. Este análisis es concluyente solo en términos del simulador, ya que no se consideró el comportamiento del consumidor al desplazar su demanda en una cantidad diferente a la señalada por el optimizador, por lo que utilizar intervalos más amplios podría no disminuir necesariamente los costos.

Finalmente, se concluye que no es necesario utilizar para el rango un intervalo que tenga un nivel de confianza alto, ya que esto resulta en factores de desplazamiento también altos que tienen poca probabilidad de ser seguidos fielmente por los consumidores que sólo ven señales

lumínicas que indican si debe aumentar o disminuir su consumo y no en qué cantidad. Para tener en cuenta esto, en la siguiente sección se plantea una corrección de la predicción de demanda tomando en cuenta el comportamiento de los consumidores ante las señales de gestión de demanda.

6.2 Corrección de la predicción de demanda utilizando modelos difusos de Mamdani

Las señales de gestión de demanda enviadas a las casas, a través de los semáforos, modificarán la demanda de los habitantes. Esto hará que se presenten variaciones en la predicción de la demanda, dependientes de las señales que se muestren en los semáforos. Para modelar esta variación, se propone la utilización de modelos difusos de Mamdani.

6.2.1 Modelación difusa de Mamdani

Los sistemas difusos pueden procesar simultáneamente información lingüística y numérica, por lo que este tipo de sistemas juegan un rol importante en aplicaciones como identificación de sistemas, reconocimiento de patrones, redes de telecomunicaciones, compresión de datos, control adaptativo, entre muchas otras [93]. Los modelos difusos de Mamdani fueron planteados por Mamdani y Assilian en 1975 [94], su estructura es de la siguiente forma:

Si x es A entonces y es B

Donde A y B son variables lingüísticas representadas por conjuntos difusos [95]. La operación de las bases de reglas difusas se puede dividir en cuatro partes, las que se detallan a continuación y puede observarse en el diagrama de la Figura 46 [96]:

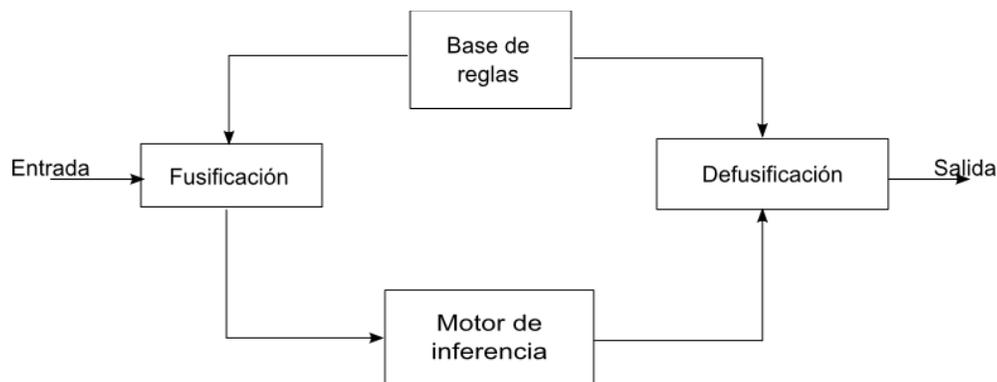


Figura 46: Diagrama sistema difuso de Mamdani [96]

Fusificación

En esta etapa se comparan las entradas con los conjuntos difusos para determinar su grado de pertenencia, el cual es utilizado posteriormente para evaluar las reglas.

Motor de inferencia

Usando los valores de pertenencia, que resultan de la etapa anterior, se evalúan las reglas obteniéndose conjuntos difusos de salida. El conjunto total de reglas se evalúa uniendo los conjuntos difusos resultantes de cada regla, con lo cual se obtiene una salida difusa.

Base de reglas

En este bloque se encuentran todas las reglas lingüísticas y la información referente a éstas como el peso o ponderación de cada una. Las reglas pueden derivarse de la experiencia de los expertos o a partir de datos de entrada y salida del mismo proceso.

Defusificación

Luego de obtenida la salida difusa, es necesario tener una salida determinística, lo que se realiza en esta etapa a través de diversos métodos como el método del máximo, en el cual la salida corresponde al valor para el cual la función de pertenencia del conjunto de salida difuso alcanza su máximo. También se tiene el método de la media del máximo, mediante el cual la salida es el promedio entre los elementos del conjunto de salida que tienen un grado de pertenencia máximo. Y finalmente, se tiene el método del centro de gravedad, en el cual la salida es el valor correspondiente al centro de gravedad de la función de pertenencia del conjunto difuso de salida.

La indentificación del sistema difuso se divide en dos tipos: la identificación de la estructura y la identificación de los parámetros. Estos tipos de identificación se desarrollan a continuación [97]:

Identificación de la estructura

La identificación de la estructura debe resolver, en general, dos problemas: encontrar las variables de entrada y relaciones entre las entradas y salidas. Para determinar las entradas se debe recurrir a un método heurístico basado en la experiencia, ya que hay un número infinito de posibles candidatos a entradas que se deben acotar. También se pueden establecer las entradas tomando un conjunto de entradas candidatas y seleccionando de éstas las que afecten la salida, tomando al sistema como una caja negra.

En teoría clásica de sistemas, determinar la relación entre entradas y salidas corresponde a determinar el orden del modelo. Un sistema difuso consiste en un conjunto de reglas del tipo “si...entonces”, en donde el número de reglas es análogo al orden del modelo.

Identificación de parámetros

En los sistemas clásicos, esto corresponde a determinar los coeficientes de la función que representa a un sistema. En un sistema difuso, los parámetros son de las funciones de pertenencia de los conjuntos difusos, lo que no difiere en gran medida del caso clásico, salvo que para los modelos difusos los parámetros son más, debido a que se consideran varias reglas y no sólo una ecuación para representar al modelo. Para ajustar estos parámetros se puede utilizar un criterio convencional, es decir, minimizar el error a la salida del sistema.

En la siguiente sección se presenta el caso de estudio, sobre el cual se utilizarán modelos difusos para determinar la variación en el consumo al utilizar gestión de demanda basada en respuesta de la demanda.

6.2.2 Generación de perfil base y reglas difusas

Se espera que las señales de gestión de demanda, que se muestran en los semáforos instalados en las casas, afecten de la manera requerida la curva de demanda de los usuarios. El efecto que tengan las señales será de mayor o menor grado dependiendo de la hora en que se presenten y su efecto no será exactamente el que espera el optimizador. Para cuantificar este cambio se propone utilizar modelación difusa de Mamdani, ya que se puede obtener una base de reglas a partir del conocimiento heurístico, como se detallará en la sección siguiente. Las entradas al modelo propuesto para la variación de la demanda en función de las señales de gestión, cuyo diagrama se encuentra en la Figura 47, corresponden al horario y el color de la luz que está mostrando en el semáforo en dicho momento del día, mientras que la salida corresponde a la variación esperada en la demanda.



Figura 47: Diagrama para la modelación del comportamiento de los consumidores

Los conjuntos de entrada, correspondientes al color de la luz del semáforo, tendría la forma que se observa en la Figura 48, ya que solo pueden tomar uno de los tres valores (amarillo, rojo o verde) y ninguno intermedio.

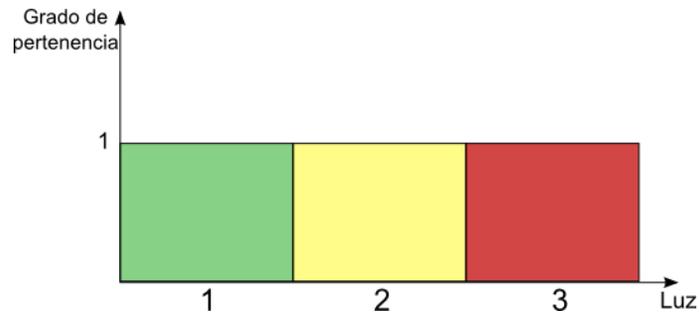


Figura 48: Conjuntos difusos para las luces del semáforo

En la Figura 49 y Figura 50 se observan las funciones de pertenencia propuestas para los conjuntos de horario y de variación, respectivamente. Se utilizan tres conjuntos en cada caso en base al perfil promedio de demanda para la comunidad (Figura 21) y el conocimiento heurístico, ya que se pueden identificar tres zonas, una corresponde a las primeras horas del día en el que el consumo del pueblo corresponde principalmente a la bomba de agua y la luminaria pública, luego en la tarde la demanda aumenta levemente a consecuencia del uso de los artefactos eléctricos en los hogares como electrodomésticos, televisión, radio, etc, y finalmente, se tiene la noche en donde aumenta considerablemente el consumo debido a que a lo anterior se agrega la iluminación eléctrica dentro de los hogares. Debido a esto, se puede observar que la mejor opción es la utilización de tres conjuntos tanto para horario del día como variación. Los valores de estas funciones se determinarán mediante algoritmos genéticos, para lo que se propone utilizar valores reales obtenidos del experimento que se detalla en la sección 6.2.3.

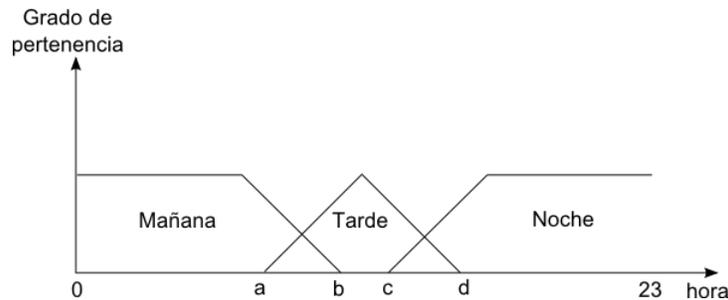


Figura 49: Conjuntos difusos para el horario

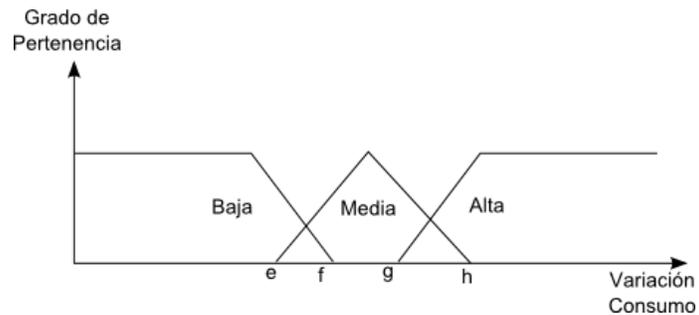


Figura 50: Conjuntos difusos para la variación de consumo

Se realizó una encuesta entre los habitantes de Huatacondo, para poder determinar su perfil base de consumo y determinar heurísticamente la base de reglas para el modelo difuso de Mamdani. La estructura de la encuesta se encuentra en el Anexo B. Ésta consistió en dividir el día en tramos de una hora desde las 7hrs hasta las 24hrs, y preguntarles que artefactos eléctricos utilizaban cada hora. La encuesta se aplicó a 17 hogares y a partir de esto, se confeccionó el perfil de consumo base para cada casa.

Luego de conocidas las horas de uso para los distintos artefactos eléctricos utilizados en cada casa para las distintas horas, se realizó una sobrestimación del perfil base, esto dado que se tomó en cuenta el uso de todos los artefactos que mencionaron, siendo que hay artefactos que sólo se ocupan una vez a la semana, como lavadora y plancha. Se utilizó una potencia genérica para los artefactos, sin diferenciar entre casas, utilizando consumos típicos para cada uno de ellos ^{2 3}, los que se presentan en la Tabla 13.

Tabla 13: Consumos típicos

Consumos	Potencia [W]
Refrigerador	350
Horno eléctrico	1000
Hervidor	1000
TV	70
Plancha	1000
Ampolletas	20
Lavadora	395
Equipo de música	120
Sierra eléctrica	1200
Taladro	500
Microondas	1000

El perfil se realizó en base a los pulsos que entrega el medidor de luz, ya que las mediciones almacenadas en el servidor de la micro-red de Huatacondo corresponden a los pulsos enviados por el medidor (800 pulsos por kWh). Por lo tanto, para cada hora del día se estimó la cantidad de pulsos, como se observa en el siguiente diagrama:

² <http://intranet.minem.gob.pe/AppWeb/DGE/CalculoConsumo>

³ <http://www.eclipse.cl/ei/consumo.htm>

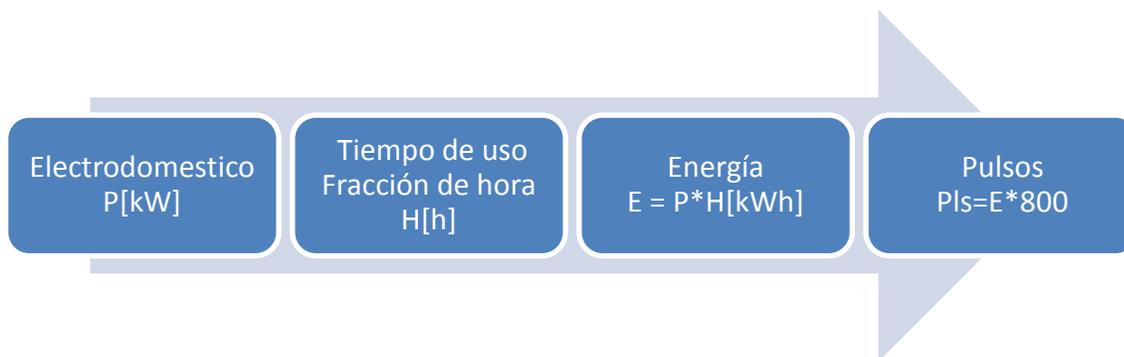


Figura 51: Procedimiento para el cálculo de pulsos

Por ejemplo, si a las 10 de la mañana se utiliza el hervidor, se considera 1[kW] por un periodo de aproximadamente 3 minutos, por lo tanto la energía utilizada por el hervidor es:

$$E = 1[kW] * 0.05[hrs] = 0.05[kWh]$$

$$Pls = 0.05[kWh] * 800 \left[\frac{pulsos}{kWh} \right] = 40 \text{ pulsos}$$

Entonces, se tendrá que para el bloque de las 10hrs el hervidor aportara con 40 pulsos, los que se sumaran a los pulsos generados por el consumo de los otros artefactos eléctricos utilizados en ese bloque horario.

De las 17 casas encuestadas, 16 cuentan con refrigerador, por lo tanto, para la confección del perfil base se consideró, como electrodoméstico de consumo permanente durante el día, para todas las casas, el uso del refrigerador. El consumo eléctrico de éste varía según los alimentos que tenga en su interior, la temperatura ambiente y la frecuencia con la que es abierto, pero en general los ciclos de refrigeración son cada 15 minutos y tienen una duración aproximada de 5 minutos [98], por lo que se considerará un consumo de energía de 20 minutos cada hora y por lo tanto, para cada bloque de una hora el refrigerador aportará con 92 pulsos.

En el siguiente gráfico se tiene el perfil base sobreestimado para la casa 5, asociada al poste 28, construido por medio de la encuesta y además el consumo promedio de dos semanas medido a través del contador de pulsos del poste 28. En uno de los viajes a Huatacondo se realizó un catastro de los contadores de pulso que se encuentran funcionando. En el anexo A se puede encontrar el mapa en donde se indican cuáles son estos.

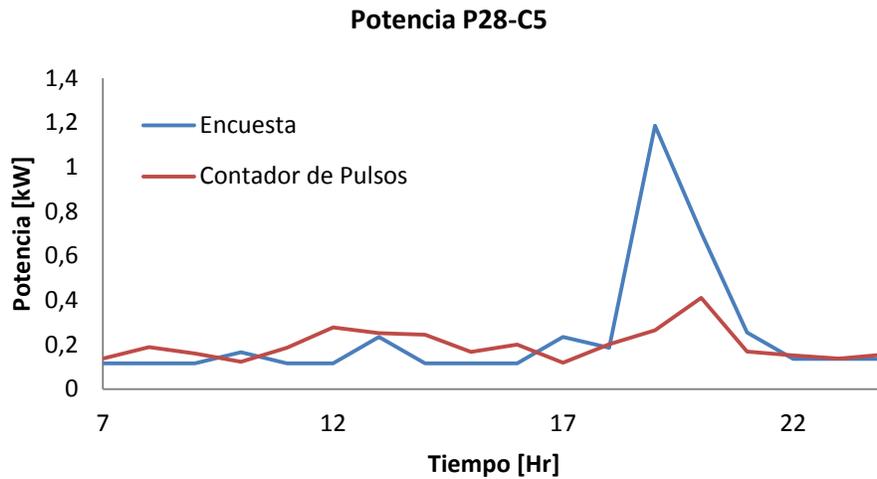


Figura 52: Perfil base de la casa 5 asociada al poste 28

Luego, para construir las reglas de manera heurística se les presentó a los encuestados, tras haber respondido como era su consumo típico, tres secuencias de semáforo, los que se muestran en la Figura 53, Figura 54 y Figura 55. El semáforo 1 representa una secuencia típica generada por el optimizador para un día soleado, el semáforo 2 corresponde a una secuencia generada para día nublado y el semáforo 3 es la secuencia que no es generalmente entregada por el optimizador. Ellos respondieron como cambiarían el uso de sus electrodomésticos, o aparatos eléctricos en general, si tuvieran que seguir las indicaciones del semáforo.

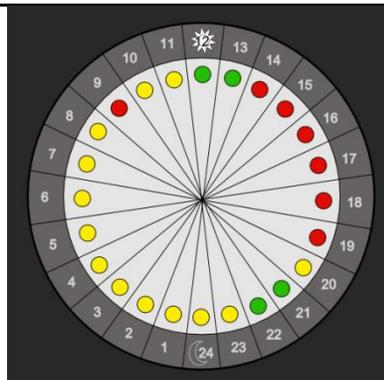


Figura 53: Semáforo 1

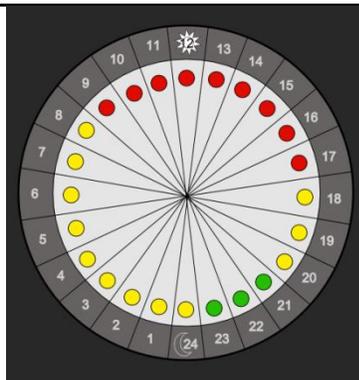


Figura 54: Semáforo 2

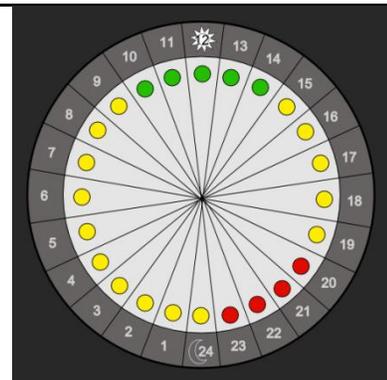


Figura 55: Semáforo 3

Se calcularon los pulsos para los resultados de las encuestas, utilizando la misma técnica usada para obtener el perfil base, de los tres casos. Luego, se calculó la variación en el consumo para cada hora, dependiendo del color de la luz y a partir de esto se extrajo la base de reglas difusas. Las reglas obtenidas de estas encuestas se encuentran en la Tabla 14, en donde L es luz, H es hora y DC es variación de consumo.

Tabla 14: Base de reglas difusas resultantes

Base de reglas difusas
R1: Si L es amarilla y H es cualquiera entonces DC es bajo
R2: Si L es roja y H es mañana entonces DC es medio
R3: Si L es roja y H es tarde entonces DC es medio
R4: Si L es roja y H es noche entonces DC es medio
R5: Si L es verde y H es mañana entonces DC es alto
R6: Si L es verde y H es tarde entonces DC es medio
R7: Si L es verde y H es noche entonces DC es alto

6.2.3 Experimento propuesto para determinar los parámetros de los conjuntos difusos

Se propone utilizar algoritmos genéticos para determinar los parámetros de los conjuntos difusos, con el objetivo de disminuir el error de predicción de la variación del consumo en función de las señales de gestión de demanda. Esta sintonización de los conjuntos se hace en base a un conjunto de datos de validación, los cuales se extraen de un experimento realizado en la micro-red. En la presente sección se detalla el experimento propuesto para determinar el conjunto de validación y el procedimiento para el ajuste de los parámetros de los conjuntos, para lo cual se propone utilizar algoritmos genéticos, los que se explican en el Anexo C.

El experimento señalado tiene como objetivo comparar las señales de gestión de demanda con la reacción real de los consumidores, en cuanto a la modificación de su perfil de demanda. Para la realización de este experimento, los semáforos instalados en las casas deben ser desconectados del sistema de gestión de demanda y ser alimentados directamente con señales pre-establecidas, para tener una mayor diversidad de escenarios, es decir, que aparezcan en distintos momentos del día los distintos colores. En este caso, dichas señales corresponden a las secuencias de los tres semáforos que se utilizaron en las encuestas para la confección de las reglas difusas del modelo (Figura 53, Figura 54 y Figura 55). La frecuencia con la cual se repiten estas señales, durante el tiempo del experimento, se relaciona con lo común que son a la salida del optimizador, por lo tanto, siendo la secuencia del semáforo 1 el tipo de secuencia más comúnmente entregado por el optimizador, es el que más veces se repite en el experimento, lo sigue la secuencia del semáforo 2 y por último la del semáforo 3.

Se intentó llevar a cabo este experimento en la comunidad de Huatacondo, para lo cual se elaboró un programa que establece que secuencia de luces mostraran los semáforos, eligiendo una de las tres secuencias utilizadas en la encuesta, dependiendo de la fecha actual. Para esto se desconectaron los semáforos de la salida EMS y desde el 16 de Diciembre del 2012 fueron alimentados por las señales programadas. La secuencia que se utilizó para cada día se puede observar en la tabla del anexo D.

Se presentaron dos problemas al realizar este experimento. El primero tiene relación con la cantidad de semáforos disponibles en Huatacondo, ya que sólo se cuenta con tres. Por esta razón, se tuvo especial cuidado en la instalación de éstos. Los tres semáforos se instalaron en casas que contaban con contador de pulso, lo que es importante para ver los cambios específicos en el perfil

de consumo de dichas casas, ya que con sólo tres semáforos no se podría apreciar la variación en el consumo general de la localidad. Luego, uno de los semáforos fue instalado en la casa que cuenta con el único teléfono del pueblo y donde toda la gente realiza y recibe sus llamadas, de esta manera más habitantes tendrían acceso a las señales. El segundo problema tuvo que ver con la falta de capacidad computacional del sistema instalado en la micro-red. Al correr el programa de los semáforos y de los contadores de pulsos, ambos necesarios para el experimento, el computador en donde están instalados deja de funcionar, por lo tanto no se pudo llevar a cabo el experimento ya que se debe dar prioridad a los programas principales que manejan el generador diésel, los paneles solares y la turbina eólica. Por esto, a continuación se detalla la metodología, para ajustar los parámetros de los conjuntos que se hubiera seguido, para que en el futuro pueda ser aplicada a esta u otro micro-red.

Como se desea ajustar los parámetros del conjunto difuso de entrada correspondiente al horario y del conjunto de salida correspondiente a la variación del consumo, utilizando algoritmos genéticos, se identifican como cromosomas los puntos a, b, c, d, e, f, g, h e i de dichos conjuntos, como se observa en la Tabla 15. Se propone, que cada cromosoma corresponda a una cadena binaria de largo 4 y que la población inicial se elija de manera aleatoria. Para el conjunto difuso de entrada correspondiente al horario, se plantea que el día se divida en tres bloques (mañana, tarde y noche), por lo tanto se pueden acotar a intervalos el valor de los cuatro cromosomas correspondientes, de manera heurística. Los intervalos que se proponen para el valor de los cromosomas correspondiente a estos conjuntos difusos, en horas, son los presentados en la Tabla 16.

Para determinar los intervalos de los cromosomas correspondientes a la variación de consumo, se utilizó la información extraída desde las encuestas. Para esto, se calculó el promedio de la variación porcentual entre el caso base y la variación del consumo para cada secuencia del semáforo mostrada en la encuesta para cada casa. En la Tabla 17 se encuentra el resultado de este cálculo, indicándose también la secuencia de colores de cada uno de estos semáforos y la hora. A partir de ésta tabla se puede tener un rango estimado para cromosomas asociados a los conjuntos difusos de variación de consumo. Se propone que para la variación del consumo se calcule el valor absoluto, por lo tanto de la Tabla 17 no se toma en cuenta el signo de la variación, sino lo rangos en los que esta se mueve.

Tabla 15: Cromosomas de los conjuntos difusos

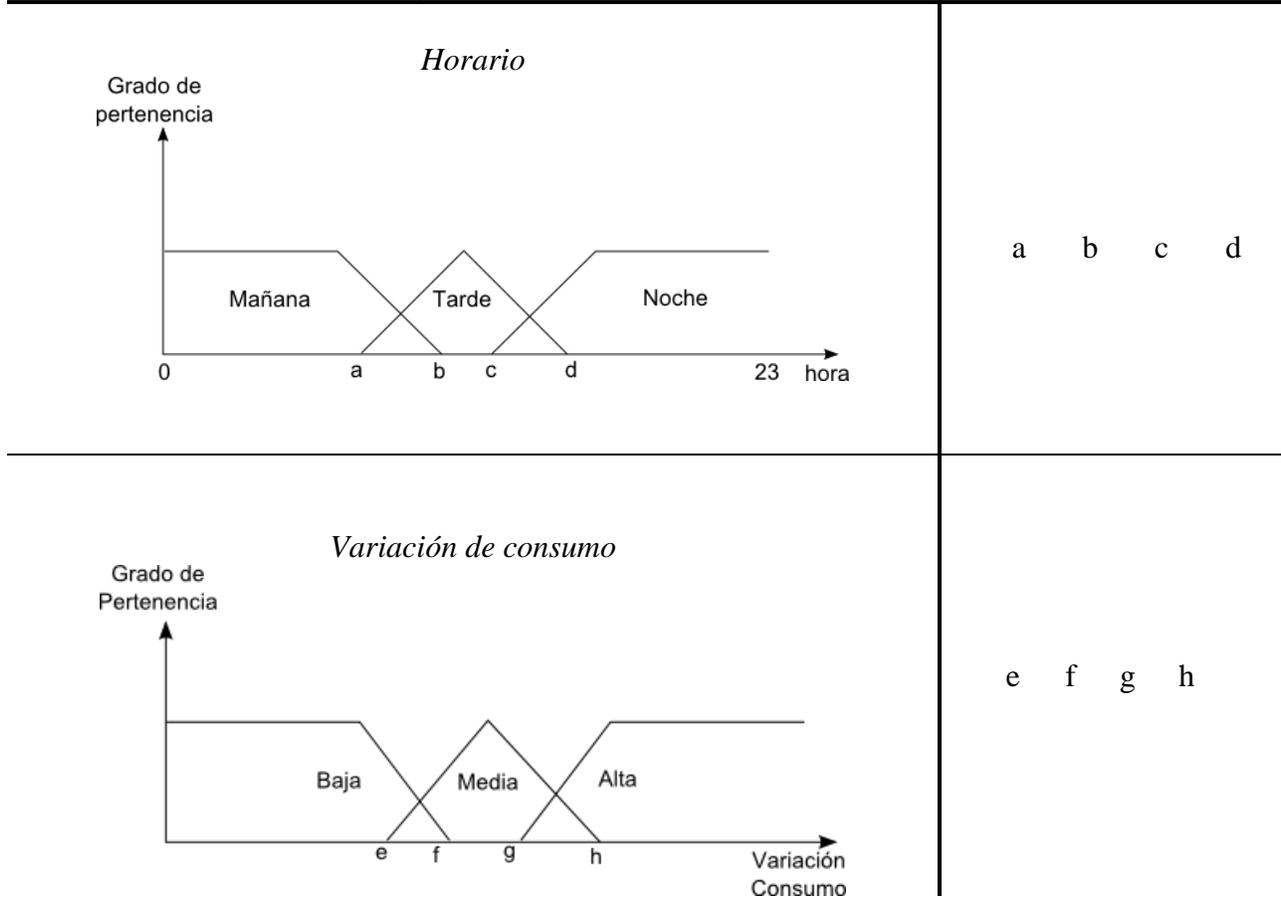


Tabla 16: Rangos para el valor de los cromosomas de los conjuntos de “Horario”

Cromosoma	Intervalo [hrs]
<i>a</i>	(12,14)
<i>b</i>	(14,15)
<i>c</i>	(18,20)
<i>d</i>	(20,22)

Tabla 17: Promedio de variación de consumo extraído desde encuestas

Promedio Variación						
Hora		Semáforo 1		Semáforo 2		Semáforo 3
7		0,00		0,00		0,00
8		-0,80		-2,39		0,00
9		-7,05		-6,24		12,53
10		-4,00		-16,76		25,72
11		20,12		-10,17		45,17
12		36,95		-5,99		95,17
13		10,23		-9,19		33,30
14		-10,23		-15,37		23,71
15		-15,58		-25,29		-5,27
16		-7,02		-14,46		0,00
17		-9,12		-25,53		-4,96
18		-3,00		5,17		-1,74
19		0,62		11,64		-10,94
20		46,68		11,31		-12,96
21		92,78		98,635		-14,92
22		40,00		42,94		-13,77
23		0,00		0,00		-4,01
24		0,00		0,00		0,00

A partir de la información extraída de las encuestas, los rangos que se definen para el valor de los cromosomas correspondientes a los conjuntos difusos de variación de consumo, son los presentados en la Tabla 18.

Tabla 18: Rangos para el valor de los cromosomas de los conjuntos de “variación de consumo”

Cromosoma	Intervalo [%]
<i>e</i>	(5,10)
<i>f</i>	(10,15)
<i>g</i>	(25,30)
<i>h</i>	(30,35)

Si se tiene el caso ideal, en el que la mayoría de los hogares cuentan con semáforo, la sintonización de los parámetros de los conjunto difusos se puede realizar utilizando la demanda total de la micro-red, ya que los cambios, debidos a la respuesta de los consumidores a los semáforos, se verán reflejados en dichos datos. En cambio, si como en la actualidad, se cuenta

con pocos semáforos, se debe realizar la sintonización tomando en cuenta sólo los datos obtenidos de los contadores de pulsos que correspondan a las casas que tienen el semáforo instalado.

Para esto se debe tomar como perfil base para la comparación, el promedio del consumo diario de cada casa involucrada en el experimento, es decir, las que cuentan con semáforo, y sumar cada uno de estos promedios para tener un único perfil base, para todo un día separado en bloques de una hora. Luego, para realizar la comparación, se toma la suma del consumo por hora de las casas participantes y se compara con el consumo de la misma hora en el perfil base, con lo que se obtiene la variación del consumo. Por lo tanto, si el experimento se hubiera realizado los 46 días que se habían propuesto inicialmente se tendría un set de datos con 1104 registros ($46 \text{ días} * 24 \text{ horas} = 1104$), los cuales consistirían en la hora, el color de la luz que se muestra en dicha hora y la variación del consumo con respecto al perfil base.

Para evaluar las soluciones, la función objetivo o de *fitting* corresponde a la minimización el error entre la variación real y la resultante de la modelación difusa de Mamdani, utilizando para esto el índice de error RMS. Es decir, los individuos cuya combinación de cromosomas resulte en un menor error serán los con mayor probabilidad de reproducción. La recombinación entre individuos se detendrá cuando el error se estabilice o comience a aumentar.

6.2.4 Discusión

Las señales de gestión de demanda que envía el sistema de gestión de energía a los habitantes de Huatacondo, mediante los semáforos instalados en sus casas, repercuten en la predicción de demanda, por lo que se propone modelar la variación en la predicción mediante modelación difusa de Mamdani.

Para determinar las reglas se realizaron encuestas a 17 casas, en las cuales se obtuvo la demanda eléctrica base, es decir, sin la influencia del semáforo y como sería la demanda en tres casos distintos. A partir de esta encuesta se determinó el perfil base de las casas y comparando este perfil con los perfiles para los tres semáforos mostrados se obtuvo una base de siete reglas difusas de manera heurística.

Para determinar los parámetros de las funciones de pertenencia de los conjuntos de horario y variación de consumo, se propone utilizar algoritmos genéticos, utilizando los datos obtenidos al realizar un experimento, en el cual se envíen señales programadas a los usuarios y se compare posteriormente como cambian su comportamiento frente al del perfil base que se obtiene de recopilar datos de días en los que no se tiene la intervención del semáforo de gestión de demanda.

En el futuro, teniendo datos reales de consumo en función de las señales de gestión y aplicando algoritmos genéticos para obtener los parámetros de las funciones de pertenencia, se podrá obtener el modelo de Mamdani para el comportamiento de los consumidores.

7 Conclusiones

Existen diversas técnicas de gestión de demanda, las cuales tienen como objetivo común aumentar la eficiencia energética desde el lado de la demanda. Las técnicas más utilizadas corresponden a la de control de carga y de respuesta de demanda. En la primera se intervienen directamente las cargas, con cuyos dueños se ha llegado a un acuerdo previamente, por otra parte las técnicas de respuesta a la demanda corresponden a programas de incentivos principalmente económicos, para modificar el consumo eléctrico.

Es relevante en las redes mantener el equilibrio entre generación y demanda, esto se hace difícil cuando se tratan de micro-redes basadas en energías renovables, donde las fuentes de energía presentan fluctuaciones. Es por esto que se presentaron diversos trabajos que respaldan el uso de acciones de gestión de demanda en micro-redes que utilizan energías renovables como medio para amortiguar las fluctuaciones presentes en las fuentes de energía renovable no convencionales, trayendo como beneficio una disminución en los costos de la energía, al dar preferencia de despacho a las renovables, frente a fuentes de energía que operan con diésel o gas.

También, para mantener el equilibrio entre demanda y generación en micro-redes, especialmente basadas en energías renovables, es importante tener una buena predicción de demanda eléctrica, ya que esta permite una correcta programación del despacho de las unidades generadoras en el corto plazo y también la planificación de inversiones en generación y distribución al largo plazo.

Este trabajo de tesis se desarrolló sobre los dos tópicos tratados en el estado del arte; gestión de demanda y predicción de demanda, basados en la micro-red inteligente instalada en Huatacondo. Se realizó un modelo para predecir la demanda eléctrica en micro-redes, utilizando como caso de estudio la micro-red allí instalada, que por la característica no-lineal de su demanda llevó a utilizar modelación difusa de Takagi y Sugeno [77]. Las variables utilizadas fueron los registros del día anterior al instante que se quiere predecir, esto se decidió basado en el estudio de correlaciones realizado en [89]. El modelo difuso utilizado, encuentra los parámetros de las consecuencias utilizando el criterio de mínimos cuadrados para cada regla. El número de reglas se eligió realizando pruebas para distintos números de reglas, escogiendo la que presentaba el mejor desempeño, esto definido como el menor RMSE resultando de esta forma cuatro modelos como candidatos. Se agregó una nueva etapa a la identificación del modelo, el análisis de estabilidad, el cual se basa en el estudio de estabilidad de las matrices de estado y de la estabilidad de las matrices que resultan al multiplicarlas de forma cruzada. De esta nueva etapa se obtuvo que de los cuatro modelos candidatos el único estable resultó ser el construido con 4 reglas.

Posteriormente, se realizaron predicciones a 192 pasos, lo que corresponde a dos días, con diferentes conjuntos de datos y el modelo escogido de la etapa anterior, observando que el error no aumenta necesariamente al usar conjuntos de datos lejanos al conjunto de entrenamiento, lo

que puede deberse a que son parecidos en el consumo. Al comparar los resultados obtenidos con los del modelo de redes neuronales implementado en [89] para tres horizontes de tiempo (1 hora, 1 día y 2 días), comparando el RMSE de ambos modelos, se logró ver una clara ventaja al utilizar modelos difusos para los tres horizontes estudiados. Se concluyó que el modelo difuso mejoró las predicciones hasta en un 14% utilizando la técnica de horizonte deslizante. Este resultado es importante para el EMS, ya que la programación puede hacerse con datos más certeros.

También se realizó una prueba en la que se entrenó el modelo con frecuencia entre 7 y 30 días con diferente cantidad de datos, para analizar la frecuencia adecuada de entrenamiento. De lo anterior se obtuvo que la incidencia de la frecuencia de entrenamiento no es notoria en el índice de error. Se espera puedan existir cambios relevantes si se entrena el modelo cada 3 meses coincidiendo con los cambios de estación, para lo que se necesitan los datos de al menos un año completo. Además, se obtiene que el entrenamiento con más datos mejora las predicciones, por lo que se debería aumentar la cantidad de datos de entrenamiento para hacer más certero al modelo.

Las predicciones se probaron en el optimizador del sistema de gestión de demanda, comparando con una simulación que utilizaba predicciones realizadas anteriormente, las que corresponden a agregar ruido aleatorio a datos reales de demanda histórica. La nueva predicción, realizada con el modelo difuso de Takagi y Sugeno, presentó un error un 11% menor que el presentado por la predicción anterior, con respecto a los datos reales de demanda. Esta mejora se reflejó en los costos, los que disminuyen un 15% en la optimización para dos días.

El segundo tema tratado corresponde a gestión de demanda de la micro-red instalada en Huatacondo, el que corresponde al tipo “respuesta de la demanda”, que consiste en enviar señales a los consumidores para que modifiquen su consumo eléctrico de manera que el despacho de las unidades sea óptimo, disminuyendo así costos. Dentro de la gestión de demanda, el trabajo de esta tesis se centra en dos aspectos específicos. El primero, es el factor de desplazamiento de carga, que es determinado por el optimizador del sistema de gestión de energía, el cual finalmente se transforma en la señal que ven los consumidores en sus hogares y corresponde a cuánto debe ser desplazada la carga para tener un despacho óptimo. El segundo, tiene relación con cómo las señales de gestión de demanda, que ven los consumidores en sus hogares, afectan a la predicción de demanda en base al comportamiento de ellos.

El factor de desplazamiento está acotado por el rango de desplazamiento de carga. En este trabajo se propuso determinar este rango de manera dinámica utilizando intervalos difusos. Para modelar el intervalo se utilizó modelación difusa de Takagi y Sugeno, y además se plantearon dos metodologías para predecir el intervalo a j pasos, ya que el optimizador utiliza predicciones a dos días. Al modelar el rango de desplazamiento con intervalos difusos se están tomando en cuenta datos históricos de variación de la demanda, y es por esta razón que se utiliza el modelo ya que así el factor de desplazamiento estará dentro de variaciones históricas de la demanda. Esto se probó en el optimizador del sistema de gestión de energía, utilizando dos intervalos con distintos niveles de confianza. Uno de los intervalos tiene un nivel de confianza de 60% y el segundo 97%, siendo el primero más estrecho. El rango superior se calculó como la variación entre la cota

superior del intervalo y la predicción de demanda, el rango inferior se calculó análogamente utilizando la cota inferior. Estos dos intervalos se compararon con el caso sin gestión de demanda, es decir, donde no hay factor de desplazamiento. La prueba resultó en que mientras mayor es el rango de desplazamiento, menores son los costos finales, esto se esperaba ya que al aumentar el rango se brinda más flexibilidad al optimizador para desplazar la demanda. Esto no necesariamente ocurrirá en la realidad, ya que los consumidores no ven cuánto tienen que variar su demanda, sólo ven la señal de aumentar (verde) o disminuir (rojo), por lo que la demanda no se desplazará exactamente como el factor de desplazamiento lo indica. Por esto, se concluye que no es necesario utilizar altos rangos de desplazamiento, lo que es análogo a intervalos más amplios, ya que resultarían factores de desplazamientos altos que tienen baja probabilidad de ser cumplidos por los consumidores.

El segundo aspecto abordado, con relación a la gestión de demanda, corresponde a cómo se modifica la predicción de demanda en función de las señales de gestión de demanda que reciben los consumidores. Para modelar la variación en la predicción se propuso la utilización de modelación difusa de Mamdani. El modelo propuesto tiene como entradas la hora y el color de las luces, mientras que la salida corresponde a la variación en la predicción de demanda. Las reglas del modelo se obtuvieron de manera heurística, mediante la aplicación de encuestas a 17 casas en Huatacondo, en las cuales se preguntó en qué horarios se utilizaban ciertos artefactos eléctricos (desde las 7:00 hrs a las 24:00 hrs), para cuatro casos. El primer caso corresponde al caso sin semáforo y los otros tres son para semáforos con distintas señales. A partir del primer caso se construyeron perfiles bases para las casas, utilizando los consumos típicos de energía de los electrodomésticos mencionados en las encuestas. También se crearon perfiles para cada semáforo, los que fueron comparados con el perfil base, para extraer de esta manera la base de siete reglas difusas. Para las funciones de pertenencia de los conjuntos de hora y variación de consumo, se propuso la utilización de algoritmos genéticos, lo cual no pudo ser llevado a cabo, pero se dejó planteado el experimento a realizar, que consiste en la entrega a los consumidores señales programadas durante un periodo de tiempo, para extraer el comportamiento que tienen frente a las señales, y así utilizar estos datos para ajustar los parámetros de las funciones de pertenencia.

En resumen, se realizó un módulo de predicción de demanda basado en modelación difusa de Takagi y Sugeno a cuyas etapas de identificación se agregó análisis de estabilidad, el cual presentó menor error que el modelo con redes neuronales diseñado también para la misma micro-red. Además, se realizó predicción para el factor de desplazamiento dinámico de carga, para ser utilizado en la gestión de demanda de la micro-red y se planteó una metodología para modelar el comportamiento de los consumidores ante las señales de gestión de demanda. Estos tres trabajos aportan al mejor comportamiento de la micro-red basadas en energías renovables, ya que se enfocan en uno de los principales problemas, el cual corresponde a la incertidumbre que representan las fuentes de energías renovables no convencionales en las que se basan estos sistemas.

8 Trabajo Futuro

Relacionado con este trabajo, a continuación se plantean cuatro propuestas de trabajo futuro que pueden ser de utilidad para el desarrollo de las micro-redes inteligentes.

Lo primero se relaciona a realizar el experimento con los contadores de pulsos y las señales programadas de gestión de demanda, para de esta forma poder ajustar los parámetros del modelo difusos de Mamdani propuesto. De esta forma, al tener los conjuntos difusos sintonizados se puede poner a prueba en línea sobre la micro-red y analizar si la optimización mejora al tomar en cuenta el impacto que tiene la gestión de demanda sobre la predicción de demanda.

También con relación a la predicción de demanda, se propone analizar la frecuencia de entrenamiento cada 3 meses, coincidiendo con los cambios de estación, teniendo al menos un año de datos de demanda, para determinar si las estaciones afectan al modelo de predicción. Para que el cambio de estación se vea reflejado en los datos, el entrenamiento debe realizarse con datos de dicha estación, por lo tanto, también se puede analizar con qué cantidad de datos de dicha estación se obtiene un modelo que realice buenas predicciones de demanda.

En cuanto a gestión de demanda, se propone utilizar en el futuro la bomba de agua como una carga controlable. Esta carga puede ser utilizada cuando el rango de desplazamiento sea muy acotado, por lo tanto se tenga poca flexibilidad para desplazar la demanda.

Finalmente, en este trabajo se utilizan intervalos difusos para determinar el rango de desplazamiento de carga. Se propone utilizar intervalos difusos para robustecer el sistema de gestión de energía de la micro-red, para que se tenga en cuenta la incertidumbre de parámetros como predicción de potencia solar, predicción de potencia eólica y predicción de demanda, en la optimización. Además, se propone que se estudie cómo influyen los cambios en el factor de desplazamiento a la vida útil de las baterías.

9 Publicaciones y Estadía de Investigación

9.1 Publicaciones generadas

- Ávila, F., Sáez, D., Jiménez-Estévez, G., Reyes L., Núñez, A. “Fuzzy Demand Forecasting in a Predictive Control Strategy for a Renewable-energy based Microgrid”, Proceedings of the European Control Conference ECC 2013, Zurich, Switzerland, July 17-19, 2013.
- Ávila F., Sáez D., Cañizares C., “Demand Side Management: Load Modeling using Affine Arithmetic” En preparación para PES 2014.
- Sáez D., Olviars D., Ávila F., Cañizares C., “Fuzzy Confidence Interval Models for the Design of a Robust EMS of Micro-grids” En preparación para IEEE Transactions on Smart Grid

9.2 Estadía de Investigación

Durante los meses de Mayo, Junio y Julio del 2013, se desarrolló una estadía de investigación en el tema “Demand Side Management: Load Modeling using Affine Arithmetic” en la Universidad de Waterloo, Canadá bajo la tutela del profesor Claudio Cañizares dentro del grupo de micro-redes.

10 Referencias

- [1] R.H. Lasseter and P. Paigi, "Microgrid: a conceptual solution," in *IEEE 35th Annual Power Electronics Specialists Conference*, 2004, pp. 4285 - 4290.
- [2] R.H. Lasseter, "Microgrids," *Power Engineering Society Winter Meeting*, vol. 1, pp. 305-308, 2002.
- [3] F. Katiraei and M.R. Iravani, "Power Management Strategies for a Microgrid With Multiple Distributed Generation Units," *IEEE Transactions on Power Systems*, vol. 21, no. 4, pp. 1821 - 1831, November 2006.
- [4] Carla Garrido-Echevería, Natalia Jiménez-Estévez, Guillermo Alvial-Palavicino, Lorenzo Reyes, and Rodrigo Palma-Behnke, "A methodology for community engagement in the introduction of renewable based smart microgrid," *Energy for sustainable development*, vol. 15, no. 3, pp. 314-323, Septiembre 2011.
- [5] Fernando Lanás, "Desarrollo y validación de un modelo de optimización energética para una micro-red," in *Memoria para optar al título de ingeniero civil electricista.*, 2011.
- [6] R. Palma-Behnke, D. Ortiz, L. Reyes, G. Jimenez-Estevéz, and N. Garrido, "A social SCADA approach for a renewable based microgrid — The Huatacondo project," in *IEEE Power and Energy Society General Meeting*, San Diego, CA, 2011, pp. 1-7.
- [7] Z. Bashir and M. El-Hawary, *Applying Wavelets to Short-Term Load Forecasting Using PSO-Based Neural Networks*. Canada: IEEE, 2009.
- [8] Goran Strbac, *Demand Side Management: Benefits and Challenges*. Londres: Elsevier Ltd., 2008.
- [9] Adeel Abbas Zaidi and Friederich Kupzog, *Microgrid Automation - A Self-Configuring Approach*. Vienna: IEEE, 2008.
- [10] Jacqueline Llanos, *Método para la Generación de Perfiles de Demanda en Comunidades Aisladas, y Predicción de Demanda a Corto Plazo, para Micro Redes basadas en Energías Renovables, Tesis para Optar al Título de Magister en Ciencias Mención Ingeniería Eléctrica*. Santiago, 2012.
- [11] M. Afshin and A. Sadeghian, "PCA-based Least Squares Support Vector Machines in Week-Ahead Load Forecasting," *IEEE Industrial & Commercial Power Systems Technical Conference*, pp. 1-6, May 2007.
- [12] A. Setiawan, I. Koprinska, and V. Agelidis, *Very Short-Term Electricity Load Demand Forecasting Using Support Vector Regression.*: IEEE International Joint Conference on Neural Network, pp 288-294, June 2009.
- [13] E.A. Feinber and D. Genethliou, "Load Forecasting," in *Applied Mathematics for Restructured Electric Power System*, J.H. Chow, F.F. Wu, and J. Momoh, Eds.: Springer, 2005, ch. 12, pp. 269-285.
- [14] Lee:W.J. and Ch.Y. Lee, *Comparative Study on Load Forecasting Technologies for Different Geographical distributed Loads.*: IEEE Power and Energy Society General

Meeting, pp 1-8, July 2011.

- [15] T. Haida and S Muto, "Regression based peak load forecasting using a transformation technique," *IEEE Transaction on Power Systems*, vol. 9, no. 4, pp. 1788-1794, November 1994.
- [16] R.F. Engle, C. Mustafa, and J. Rice, "Modelling peak electricity demand," *Journal of forecasting*, vol. 11, no. 3, pp. 241-251, April 1992.
- [17] J. Lu and X. Zhang, "A real-time adaptive forecasting algorithm for electric power load," *IEEE/PES Transmission and Distribution Conference and Exhibition*, pp. 1-5, 2005.
- [18] M.Y. Cho, J.C Hwang, and C.S. Chen, "Customer short term load forecasting by using ARIMA transfer function model," *International Conference on Energy Management and Power Delivery*, vol. 1, pp. 317-322, November 1995.
- [19] A Jain and E Srinivas, "Short term load forecasting using fuzzy adaptive inference and similarity," *World Congress in Nature & Biologically Inspired Computing*, pp. 1743-1748, December 2009.
- [20] W. Dai and P. Wanh, "Application of pattern recognition and artificial neural network to load forecasting in electric power system," *IEEE International Conference on Natural Computation*, 2007.
- [21] Z.A. Bashir and M.E. El-Hawary, *Applying Wavelets to Short-Term Load Forecasting Using PSO-Based Neural Networks.*: IEEE Transaction on power systems, Vol. 24, No. 1, February 2009.
- [22] Ch. Hsu and Ch. Chen, "Regional load forecasting in Taiwan: Applications of artificial neural networks," *Energy Conversion and Management*, vol. 44, no. 12, pp. 1941-1949, July 2003.
- [23] Y. Lu, "Short-term load forecasting method based on structural neural network," *IEEE World Congress on Intelligent Control and Automation*, pp. 4434-4438, June 2008.
- [24] K.H. Osman, M.L Awad, and T.K. Mahmoud, "Neural network based approach for short-term load forecasting," *IEEE Power System Conference and Exposition*, pp. 1-8, March 2009.
- [25] N. Kandil, R. Wamkeue, M. Saad, and S. Georges, "An efficient approach for shorterm load forecasting using artificial neural networks," *IEEE ISIE*, pp. 1928-1932, July 2006.
- [26] H. Ho et al., "Short term load forecasting of Taiwan power system using a knowledge based expert system," *IEEE Transactions on Power Systems*, vol. 5, pp. 1214-1221, 1990.
- [27] S. Rahman and O. Hazmin, "Load forecasting for multiple sites: Development of an expert system-based technique," *Electric power systems research*, vol. 39, pp. 161-169, 1996.
- [28] A. Pratondo, *Fuzzy Rule Base for Analytical Demand Forecasting Enhancement.*: IEEE Second International Conference on Advances in Computing, Control and Telecommunication Technologies, 2010.
- [29] V.H Hinojosa and A Hoese, *Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms.*: IEEE Transactions on Power Systems, Vol. 25, No. 1, February 2010.
- [30] S. Sachdeva and Ch. Verma, "Load forecasting using fuzzy methods," *Power System*

- Technology and IEEE Power India Conference*, pp. 1-4, October 2008.
- [31] H. Xu, J. Wang, and S. Zheng, "Online daily load forecasting based on support vector machines," *IEEE International Conference on Machine Learning and Cybernetics*, vol. 7, pp. 3985-3990, August 2005.
- [32] S. Fan, K. Methaprayoom, and W.J. Lee, "Multi-area load forecasting for system with large geographical area," *IEEE/IAS Industrial and Commercial Power System Technical Conference*, pp. 1-8, May 2008.
- [33] T. Senjyu, H. Takara, K. Uezato, and T Funabashi, "One-hour ahead load forecasting using neural network," *IEEE Transactions on power systems*, vol. 17, no. 1, pp. 113-118, February 2002.
- [34] Ch. Jaipradidtham, *Next Day Load Demand Forecasting of Future in Electrical Power Generation on Distribution Networks using Adaptative Neuro-Fuzzy Inference.*: First International Power Energy Conference, November 2006.
- [35] K. Liu et al., *Comparison of Very Short-term Load Forecasting Techniques.*: IEEE Transactions on power systems, Vol. 11, No. 2, May 1996.
- [36] P. Chan, W. Chen, W.Y. NG Wing, and D. Yeung, *Multiple Classifier System for Short Term Load Forecast of Microgrid.*: International Conference on Machine Learning and Cybernetics, July 2011.
- [37] N. Amjady, F. Keynia, and H. Zareipour, *Short-Term Load Forecast of Microgrid by a New Bilevel Prediction Strategy.*: IEEE Transactions on Smart Grid, Vol. 1, No. 3, December 2010.
- [38] N Amjady and F Keyna, "Electricity Market Price Spike Analysis by a Hybrid Data Model and Featured Selection Technique," *Electr. Power Syst. Res.*, vol. 80, no. 3, pp. 318-327, March 2010.
- [39] N. Amjady and F. Keyna, *Day-ahead price forecasting of electricity markets by mutual information technique and cascaded neuro-evolutionary algorithm.*: IEEE Trans. Power Syst., Vol. 24, No 1, pp. 306-318, Feb 2009.
- [40] R. Storn and K. Price, *Differential evolution-A simple and efficient heuristic for global optimization over continuous spaces.*: Journal of Global Optimization, Vol. 11, No. 4, pp. 341-359, Dec 1997.
- [41] P. Chan, W.-C. Chen, Wing W. Y. NG, and D. Yeung, *Multiple Classifier System for Short Term Load Forecast of Microgrid.*: Internation Conference on Machine Learning and Cybernetics, July 2011.
- [42] Huibini Sui, Ying Sun, and Wie-Jen Lee, *A Demand Side Management Model Based on Advanced Metering Infrastructure.*: IEEE, 2011.
- [43] Hans Nilsson, *The many faces of demand-side management.* Stockholm, 1994.
- [44] Chen Xiang-ting, Zhou Yu-hui, Duan Wei, Tang Jie-bin, and Guo Yu-xiao, *Desing of Intelligent Demand Side Management System Respond to Varieties of Factors.* Beijing, China, 2010.
- [45] Michael Angelo Pedrasa, Ted Spooner, and Iain MacGill, *Scheduling of Demand Side Resources Using Binary Particle Swarm Optimization.*: IEEE, 2009.

- [46] A Molina, J.A Gabaldón, and C Álvarez, *Implementation and assessment of physically based electrical load models: application to direct load control residential programmes*. España: IEEE, 2003.
- [47] Vandad Hamidi, Furong Li, Yao Liangzhong, and Masoud Bazargan, *Domestic Demand Side Management for Increasing the Value of Wind*. Bath, UK, 2008.
- [48] Molina A., Roldán C., Fuentes A., Gómez E., Ramírez-Rosado I.J., Lara P., Domínguez J.A., García-Garrido E., Tarancón E. Gabaldón A., *Assessment and Simulation of Demand-Side Management Potential in Urban Power Distribution Networks*. Cartagena, España: IEEE.
- [49] J Han and M.A Piette, *Solutions for Summer Electric Power Shortages: Demand Response and its Applications in Air Conditioning and Refrigerating Systems.*, 2008.
- [50] M Aldabi and E Saadany, "A summary of demand response in electricity markets," *Electric power systems research*, vol. 78, no. 11, pp. 1989–1996, November 2008.
- [51] Daniel O'Neil, Marco Levorato, Andrea Goldsmith, and Urbashi Mitra, "Residential demand response using reinforcement learning," in *First IEEE International Conference in Smart Grid Communications*, 2010.
- [52] S Pourmousavi and M Nehrir, "Demand response for smart microgrid: Initial results," , January 2011, pp. 1- 6.
- [53] P Khajavi, H Abniki, and A.B Arani, *The Role of Incentive Based Demand Response Programs in Smart Grid.*: IEEE, 2011.
- [54] Kumar Nunna and Suryanarayana Doolla, "Demand response in smart microgrids," in *Innovative smart grid technologies*, December 2011, pp. 131-136.
- [55] Weihao Hu, Zhe Chen, and Birgitte Bak-Jensen, *Optimal Load Response to Time-of-Use Power Price for Demand Side Management in Denmark*. Denmark: IEEE, 2010.
- [56] Joseph Tate and Jana Sebestik, *Interactive Lessons Addressing Wind Integration and Time-of Use Pricing*. Toronto: IEEE, 2011.
- [57] Alexander Thornton and Carlos Rodríguez, *Distributed Power Generation in the United States*. Madrid: Elsevier Ltd., 2011.
- [58] Dirk Westermann and Andreas John, *Demand Matching Wind Power Generation with Wide-Area Measurement and Demand Side Management*. Ilmenau, Alemania: IEEE, 2007.
- [59] Paolo Piagi and Robert Lasseter, *Autonomous Control of Microgrids*. Montreal: IEEE, 2006.
- [60] Robert Lasseter et al., *The CERTS MicroGrid Concept*. California, 2002.
- [61] THE SMART GRID: AN INTRODUCTION. [Online]. <http://energy.gov/oe/downloads/smart-grid-introduction-0>
- [62] Fabrice Saffre and Richard Gedge, *Demand-Side Management for the Smart Grid*. Abu Dhabi: IEEE, 2010.
- [63] Friederich Kupzog, Tehseen Zia, and Abbas Zaidi, *Automatic Electric Load Identification in Self-Configuring Microgrids*. Vienna: IEEE, 2009.
- [64] Adeel Abbas Zaidi and Friederich Kupzog, *Microgrid Automation - A Self-Configuring*

Approach. Vienna: IEEE, 2008.

- [65] Adeel Abbas Zaidi, Friederich Kupzog, and Peter Palensky, *Load Recognition for Automated Demand Response in Microgrids*. Vienna: IEEE, 2010.
- [66] Luigi Martirano, Serena Fornari, Alessandro Di Giorgio, and Francesco Liberati, "A case study of a commercial/residential microgrid integrating cogeneration and electrical local users," in *12th International Conference on Environment and Electrical Engineering (EEEIC)*, Wroclaw, Poland, 2013, pp. 363 - 368.
- [67] E. Barklund, M. Prodanovic, and C. Hernandez-Aramburo, "Energy Management in Autonomous Microgrid Using Stability-Constrained Droop Control of Inverters," *IEEE Transactions on Power Electronics*, vol. 23, no. 5, pp. 2346 - 2352, September 2008.
- [68] V. Hamidi and F., Robinson, F. Li, *Responsive Demand in Network with High Penetration of Wind Power*. Bath, UK.: IEEE, 2008.
- [69] Chenye Wu, Mohsenian-Rad Hamed, Jianwei Huang, and Amy Yuexuan Wang, *Demand Side Management for Wind Power Integration in Microgrid Using Dynamic Potential Game Theory*. China: IEEE, 2011.
- [70] Bingnan Jiang and Yunsi Fei, "Dynamic residential demand response and distributed generation management in smart microgrid with hierarchical agents," *Energy Procedia*, vol. 12, pp. 76-90, September 2011.
- [71] R. Palma-Behnke, C. Benavides, E. Aranda, J. Llanos, and D. Sáez, *Energy Management System for a Renewable based Microgrid with a Demand Side Management Mechanism*. Santiago: IEEE, 2011.
- [72] E Matallanas et al., *Neural network controller for Active Demand-Side Management with PV energy in the residential sector*. Madrid: Elsevier Ltda, 2011.
- [73] I.C. Paschalidis, Binbin Li, and M.C. Caramanis, "Demand-Side Management for Regulation Service Provisioning Through Internal Pricing," *IEEE Transactions on Power Systems*, vol. 27, no. 3, pp. 1531 - 1539, August 2012.
- [74] T. Logenthiran and Tan Zong Shun, "Multi-Agent System for Demand Side Management in smart grid," in *IEEE Ninth International Conference on Power Electronics and Drive Systems (PEDS)*, Singapore, 2011 , pp. 424 - 429.
- [75] C. Ibars and L. Giupponi, "Distributed Demand Management in Smart Grid with a Congestion Game," in *First IEEE International Conference on Smart Grid Communications (SmartGridComm)*, Gaithersburg, MD, 2010, pp. 495 - 500.
- [76] R. Babuska, *Fuzzy Systems, Modeling and Identification*.
- [77] T. Takagi and M. Sugeno, *Fuzzy Identification of Systems and its Applications to Modeling and Control*. Tokyo: IEEE, 1985.
- [78] M. Jamshidi, André Titli, Lotfi Z., and S. Boverie, *Applications of Fuzzy Logic*. New Jersey: Prentice Hall, 1997.
- [79] D. Sáez and R. Zuñiga, *Cluster Optimization for Takagi & Sugeno Fuzzy Models and Its Application to a Combined Cycle Power Plant Boiler*. Santiago, 2004.
- [80] D. Sáez and A Cipriano, "A New Method for Structure Identification of Fuzzy Models and its Application to a Combined Cycle Power Plant," *Engineering Intelligent Systems for*

- Electrical Engineering and Communications*, vol. Vol. 9, no. 2, pp. 101-107, 2001.
- [81] K. Passino and S. Yurkovich, *Fuzzy Control*. Ohio: Addison Wesley, 1998.
- [82] K. Tanaka and M. Sano, *On the Concepts of Regulator and Observer of Fuzzy Control Systems.*: IEEE World Congress on Computational Intelligence, vol 2. pp. 767-772, June 1994.
- [83] Zou Huichao, Lei Junwei, and Yu Hongyun, "Extended Lyapunov Stability Theorem and Its Applications in Control System with Constrained Input," *International Symposium on Computer Network and Multimedia Technology*, pp. 1-4, Enero 2009.
- [84] Mohammed Dahleh, Munther Dahleh, and George Verghese, "Internal (Lyapunov) Stability," in *Lectures on Dynamic Systems and Control*, Massachusetts Institute of Technology, Ed., ch. 13.
- [85] H. Khalil, *Nonlinear Systems*, 3rd ed. Michigan: Prentice Hall, 2002.
- [86] Z. Lendek, T Marie, R. Babuska, and B. De Schutter, *Stability Analysis and Nonlinear Observer Design Using Takagi-Sugeno Fuzzy Models*. Poland: Springer, 2010.
- [87] K. Tanaka and M. Sugeno, *Stability Analysis and Design of Fuzzy Control Systems*. Japan: Elsevier, 1990.
- [88] R. Palma-Behnke et al., *A Microgrid Energy Management System Based on the Rolling Horizon Strategy*. Santiago: IEEE, 2011.
- [89] J. Llanos, *TESIS: MÉTODO PARA LA GENERACIÓN DE PERFILES DE DEMANDA EN COMUNIDADES AISLADAS Y PREDICCIÓN DE DEMANDA DE CORTO PLAZO, PARA MICRO-REDES BASADAS EN ENERGÍAS RENOVABLES*. Santiago, 2012.
- [90] Igor Škrjanc, Sašo Blažič, and Osvaldo Agamennoni, "Identification of dynamical systems with a robust interval fuzzy model," *Automatica*, vol. 41, no. 2, pp. 327–332, February 2005.
- [91] Igor Škrjanc, "Confidence interval of fuzzy models: An example using a waste-water treatment plant," *Chemometrics and Intelligent Laboratory Systems*, vol. 96, no. 2, pp. 182–187, April 2009.
- [92] Igor Skrjanc, "Fuzzy confidence interval por pH titration curve," *Applied mathematical modelling*, vol. 35, no. 8, pp. 4083-4090, August 2011.
- [93] P. Liu, "Mamdani Fuzzy System: Universal approximator to a class of random processes," *IEEE Transactions on fuzzy systems*, vol. 10, no. 6, December 2002.
- [94] E.H. Mamdani and S. Assilian, "An experiment in linguistic synthesis with a fuzzy logic controller," *International Journal of Man-Machine Studies*, vol. 7, no. 1, pp. 1-13, January 1975.
- [95] W. L. Tung and Chai Quek, "A mamdani-takagi-sugeno based linguistic neural-fuzzy inference system for improved interpretability-accuracy representation," *IEEE International Conference on Fuzzy Systems*, pp. 367-372, 2009.
- [96] Hyoungki Lee, J. Jung, K. Choi, J Park, and H. Myung, "Fuzzy-logic-assisted interacting multiple model (FLAIMM) for mobile robot localization," *Robotics and Autonomous Systems*, vol. 60, no. 12, pp. 1592-1606, December 2012.
- [97] M. Sugeno and T. Yasukawa, "A fuzzy-logic-based approach to qualitative modeling,"

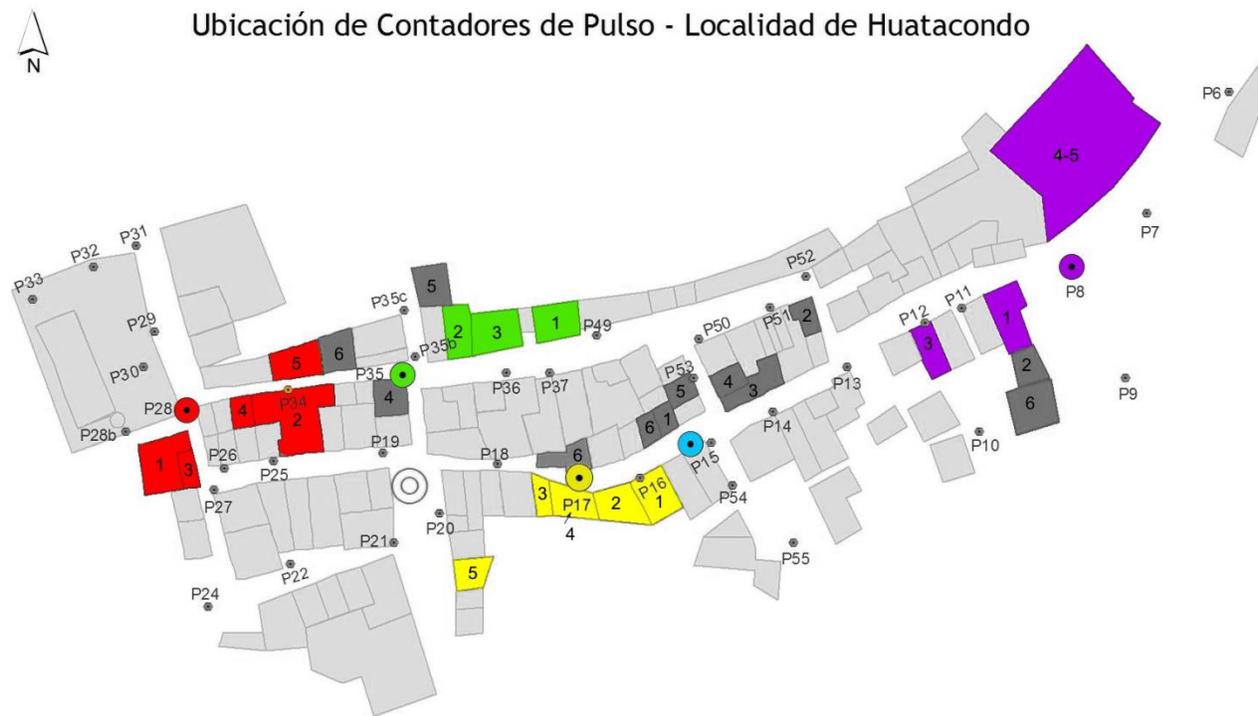
IEEE Transactions on Fuzzy Systems, vol. 1, no. 1, February 1993.

- [98] J Van den Keybus and R Belman, *Energy consumption of domestic refrigerators using electronic energy saving devices*.
- [99] Colin Reeves, *Foundations of genetic algorithms*.: Morgan Kaufmann Publishers, 1999.
- [100] K Belarbi, F Titel, W Bourebia, and K Benmahammed, "Design of Mamdani fuzzy logic controllers with rule base minimisation using genetic algorithm," *Engineering applications of artificial intelligence*, vol. 18, no. 7, pp. 875-880, October 2005.
- [101] H. Mori and A. Yuihara, "Deterministic annealing clustering for ANN-base short-term load forecasting," *IEEE Transaction on Power Systems*, vol. 16, no. 3, pp. 545-552, August 2001.

11 Anexos

11.1 Anexo A

A continuación se presenta el mapa de casas en Huatacondo, en el cual coloreadas se encuentran las casas cuyos contadores de pulsos funcionan correctamente. En gris se encuentran las casas conectadas a contadores de pulso, pero que no se encuentran en funcionamiento. El color corresponde al poste al que se encuentran conectadas los medidos de las casas, los cuales tienen asociado un número. Las casas también cuentan con un número y en el servido se puede encontrar la información del consumo de cada casa buscando el poste y número de casa.



11.2 Anexo B

A continuación se presenta el formato de encuesta realizada en Huatacondo.

Nombre: _____

Casa (ubicación en el mapa): _____

Caso: Base Reloj 1 Reloj 2 Reloj 3

Hora	Refrigerador	Horno Eléctrico	Hervidor	TV	Plancha	Lavadora	Equipo De música	Herramienta (especificar)	Microondas	Ampolleta	Otros
7											
8											
9											
10											
11											
12											
13											
14											
15											
16											
17											
18											
19											
20											
21											
22											
23											
24											

11.3 Anexo C

Algoritmos genéticos

El termino “Algoritmos genéticos” fue utilizado por primera vez por John Hollan, en su libro “*Adaptation in Natural and Artificial Systems*” de 1975. La motivación original, para el enfoque de los algoritmos genéticos corresponde a una analogía biológica de la supervivencia del más apto. Por ejemplo, cuando se realiza reproducción selectiva en plantas o animales, se valora más a los descendientes que tienen ciertas características deseadas, las cuales son determinadas a un nivel genético por cómo los cromosomas de los padres se combinan. En el caso de algoritmos genéticos, se utiliza una población de cadenas, también denominados cromosomas, los cuales se recombinan utilizando analogías genéticas como crossover y mutación, mientras que la búsqueda es guiada por la evaluación de una función objetivo para cada cadena de la población. Las cadenas que representan una mejor solución de la función objetivo, se identifican y se les da mayor posibilidad de reproducirse [99].

Las dos principales etapas de algoritmos genéticos corresponden a crossover y a mutación. La primera corresponde básicamente a reemplazar algunos de los genes en uno de los padres por los genes correspondiente del otro padre. Por ejemplo, dado los padres P1 y P2, se realiza crossover a un punto en el punto 3, obteniéndose los descendientes P1’ y P2’, como se observa a continuación.

P1	1	0	1	0	0	1	0	P1’	1	0	1	1	0	0	1
			X												
P2	0	1	1	1	0	0	1	P2’	1	1	1	0	0	1	0

Luego, esta la etapa de mutación, en la cual un subconjunto de genes es escogido de manera aleatoria y su valor es modificado. Por ejemplo, en el caso de la cadena de string binarios 01, si se mutan los genes 3 y 5, la cadena resultante sería:

1 0 0 1 1 0 1

Si no se trata de cadenas binarias, entonces el nuevo valor del gen puede ser un valor aleatorio, pero si existe alguna relación entre genes, es recomendable restringir los valores a los que estén cercanos al valor original. La mutación usualmente se considera como una función secundaria, la cual ayuda a mantener a la densidad de población en un nivel razonable. Luego de que se aplica el crossover y la mutación, se tiene lo que se denomina una nueva población.

Cuando se trabaja con cadenas binarias para evaluar la aptitud de un individuo (x_i), se transforma el cromosoma de base binaria a base 2 y luego al intervalo (a_i, b_i), que corresponde al rango de búsqueda. Por ejemplo, si se tiene un cromosoma:

10101

Su valor en base dos sera:

$$n = 2^0 * 1 + 2^1 * 0 + 2^2 * 1 + 2^3 * 0 + 2^4 * 1 = 21$$

Si se tiene un intervalo (a, b) , el parámetro asociado al cromosoma adopta el valor:

$$x = a + \left(\frac{(b - a) * n}{2^l - 1} \right) \quad (55)$$

En donde l corresponde al largo de la cadena, que en este caso es 5. Con este valor se evalua la función objetivo, lo que permite conocer la aptitud de cada individuo. También se puede evaluar la probabilidad de supervivencia según la aptitud del cromosoma, lo cual se hace mediante el cuociente entre el valor de la función objetivo evaluada en el valor del parámetro asociado al cromosoma ($f(x_i)$), y la suma del valor de la función objetivo de toda la población ($\sum f(x_i)$). La probabilidad del cromosoma i es:

$$p_i = \frac{f(x_i)}{\sum f(x_i)} \quad (56)$$

Como se mencionó, en este trabajo se propone aplicar algoritmos genéticos para ajustar los conjuntos de entrada y salida para un modelo difuso de Mamdani. En [100] Belarbi et al, se aplican algoritmos genéticos a controladores difusos de Mamdani, específicamente para disminuir el número de reglas difusas.

11.4 Anexo D

Secuencias para el experimento según fecha

Día	Mes	Año	Secuencia	Día	Mes	Año	Secuencia
16	12	2012	Semaforo3	8	1	2013	Semaforo2
17	12	2012	Semaforo3	9	1	2013	Semaforo3
18	12	2012	Semaforo3	10	1	2013	Semaforo3
19	12	2012	Semaforo2	11	1	2013	Semaforo3
20	12	2012	Semaforo2	12	1	2013	Semaforo1
21	12	2012	Semaforo2	13	1	2013	Semaforo1
22	12	2012	Semaforo1	14	1	2013	Semaforo1
23	12	2012	Semaforo1	15	1	2013	Semaforo1
24	12	2012	Semaforo1	16	1	2013	Semaforo2
25	12	2012	Semaforo1	17	1	2013	Semaforo1
26	12	2012	Semaforo1	18	1	2013	Semaforo1
27	12	2012	Semaforo1	19	1	2013	Semaforo1
28	12	2012	Semaforo1	20	1	2013	Semaforo2
29	12	2012	Semaforo1	21	1	2013	Semaforo2
30	12	2012	Semaforo1	22	1	2013	Semaforo2
31	12	2012	Semaforo1	23	1	2013	Semaforo2
1	1	2013	Semaforo1	24	1	2013	Semaforo2
2	1	2013	Semaforo2	25	1	2013	Semaforo1
3	1	2013	Semaforo2	26	1	2013	Semaforo1
4	1	2013	Semaforo3	27	1	2013	Semaforo1
5	1	2013	Semaforo2	28	1	2013	Semaforo3
6	1	2013	Semaforo2	29	1	2013	Semaforo3
7	1	2013	Semaforo2	30	1	2013	Semaforo1

11.5 Anexo E

Código de “Estabilidad”: Programa para analizar la estabilidad de modelos difusos.

```
function B = Estabilidad(G)
%Fernanda Àvila
%Noviembre-2012
%
%Estabilidad(G)
%
%G: Matriz con los parametros de las consecuencias, cada regla en una fila
%
%   yr=gr1*y(t-1)+gr2*y(t-2)+....+grn*y(t-n)
%
%   g11  g12  g13.....g1n
%   g21  g22  g23.....g2n
%G= ...
%   gr1  gr2  gr3.....g3n
%
l=length(G);
r=size(G,1);
I=eye(l-1);
Z=zeros(l-1,1);
I2=[I Z];
%Construccion de matrices A
for i=1:r
    A(:, :, i)=[G(i, :);I2];
end

p=0;
for i=1:r
    e=all(abs(eig(A(:, :, i)))<=1);
    d=det(A(:, :, i));
    if d==0
        display(strcat('Matriz A', num2str(i), ' singular'));
        p=1;
        break
    else
        if e==1
            display(strcat('Matriz A', num2str(i), ' es estable'));
        else
            display(strcat('Matriz A', num2str(i), ' es inestable'));
            p=1; %Significa que encontro inestabilidad
            break
        end
    end
end
end
```

```

k1=0;
if p==1
    display('Termino programa');
else
    for i=1:r
        if k1==0 %aun no encuentra inestabilidad
            for j=1:r
                AA=all(abs(eig(A(:, :, i)*A(:, :, j)))<=1);
                if AA ==1
                    display(strcat('Matriz A', num2str(i), 'A', num2str(j), '
es estable'));
                else
                    display(strcat('Matriz A', num2str(i), 'A', num2str(j), '
es inestable'));
                    k1=1;
                end
            end
        else
            display ('Sistema Inestable')
            break
        end
    end
    display('Sistema Estable')
end

```

