



UNIVERSIDAD DE CHILE

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

**DISEÑO DE ESTRATEGIA DE CONTROL PARA GESTIÓN
DE DEMANDA DE MICRO-REDES AISLADAS**

**MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL
ELÉCTRICO**

TOMISLAV ANDRÉS ROJE GODOY

PROFESORA GUÍA:
DORIS SÁEZ HUEICHAPAN

MIEMBROS DE LA COMISIÓN:
MARCOS ORCHARD CONCHA
GUILLERMO JIMÉNEZ ESTÉVEZ

SANTIAGO DE CHILE
2015

**RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE:** Ingeniero Civil Eléctrico
POR: Tomislav Andrés Roje Godoy
FECHA: Enero 2015
PROFESORA GUÍA: Doris Sáez Hueichapan

DISEÑO DE ESTRATEGIA DE CONTROL PARA GESTIÓN DE DEMANDA DE MICRO-REDES AISLADAS

Las micro-redes han surgido como solución para aquellas comunidades que se encuentran aisladas y desconectadas de los grandes sistemas de energía. En estas micro-redes, los recursos renovables de generación son escasos y de alta variabilidad, por lo que es crítico definir un esquema de operación que optimice la operación, que es el sistema de gestión de la energía (*Energy Management System – EMS*). Una de las estrategias con las que se cuenta, es realizar gestión de la demanda (*Demand Side Management – DSM*), que busca modificar el consumo de los usuarios. Para diseñar una estrategia de DSM, es de importancia tener una estimación de la respuesta de los usuarios frente a ella, para así determinar entre qué rangos se puede esperar que los usuarios varíen su consumo y determinar qué indicaciones enviar al consumidor para generar una respuesta deseada.

En la comunidad de Huatacondo, al norte de Chile, se encuentra instalada una micro-red aislada desde el año 2010. Esta micro-red cuenta con un EMS que se encarga del despacho de la energía y busca minimizar los costos de operación. La estrategia de DSM implementada consiste en un semáforo indicativo que puede mostrar las luces verde, amarilla y roja, correspondientes a aumentar, mantener y disminuir el consumo, respectivamente. Si bien las señales mostradas por el semáforo tienen un significado intuitivo, no se tiene una cuantificación de la respuesta que generan sobre los usuarios, por lo que este conocimiento no se incorpora al proceso de optimización.

En esta memoria se aborda el problema de modelar la respuesta para tener una estimación del rango real en el que responderán los usuarios, con el fin de generar una gestión de demanda adecuada sobre ellos y así, optimizar el funcionamiento de la micro-red. Con la obtención de un modelo se posibilita la inclusión de este conocimiento al proceso de optimización del EMS. Dado que se cuenta con pocos datos del DSM funcionando, se desarrolla un simulador de consumo con y sin gestión de demanda para la comunidad, que genera datos que permiten modelar la respuesta de los usuarios en base a la hora y color del semáforo que se tienen como entradas. Este modelo se compara con una tabla obtenida a partir del cálculo de las medias de los datos de entrenamiento. Con esta modelación, se pueden determinar los factores de desplazamiento máximos y mínimos esperados para cada hora.

Los resultados simulados en el optimizador fuera de línea del EMS con el método propuesto muestran una disminución de los costos de combustible diésel utilizado, reduciéndose hasta un 3.55% respecto a un caso base sin DSM.

A mis padres

Agradecimientos

Agradezco a mis padres, Carmen y Tomislav, por su amor, comprensión, por la educación y valores que me han entregado que me han formado como persona. También mis abuelos, tíos y primos, por su preocupación y cariño. A mi Amigo, por su infinita ayuda y cariño.

También a mis amigos. Los del colegio, los *Showas*, por los casi 12 años de conocerlos y todas juntas que dieron (y darán) lugar a tantas anécdotas y risas. A los de la U: a los que conozco desde que entré a plan común (e incluso un poco antes) y a los que conocí entrando a eléctrica, los chicos del *Tomí's lab*, gracias por su alegría, su compañía en estos 6 años de carrera, y su apoyo. A la distancia, a quienes conocí en Cergy y a quienes espero ver nuevamente ya como *Ingeniero*. Gracias a todos por su amistad, su generosidad, la buena disposición, motivación, por entregar infinitos momentos memorables a lo largo de todos estos años y por los pequeños momentos de relajó y buena onda cuando se estaba en las semanas más difíciles de la U.

Agradecer los profesores que han sido parte de mi formación académica. En especial a mi profesora guía, Doris Sáez, por todo su apoyo, su constante preocupación y sus gestiones para visitas en terreno tanto en El Romeral como en Huatacondo. También al profesor Marcos Orchard por su enorme contribución a este trabajo.

A todos aquellos que me apoyaron, me preguntaban cómo iba avanzando mi memoria, me dieron sus consejos, ideas, críticas y material: se pasaron (en especial a Luis). A la comunidad de Huatacondo por recibirme (así como a tantos otros estudiantes) y su disposición para hacer investigaciones en torno a este proyecto.

Finalmente, agradecer a: proyecto FONDECYT no. 1140775 y Solar Energy Research Center (SERC) CONICYT: FBO16, CONICYT/FONDAP/15110019.

Tabla de contenido

1.	Introducción	1
1.1.	Objetivos	1
1.1.1.	Objetivo general	1
1.1.2.	Objetivos específicos.....	2
1.2.	Alcances	2
1.3.	Estructura de la memoria.....	2
2.	Revisión bibliográfica.....	4
2.1.	Micro-redes	4
2.2.	Sistema de gestión de la energía (EMS).....	5
2.3.	Gestión de la demanda (DMS)	6
2.3.1.	Estrategias de DSM.....	8
2.4.	Modelación del consumidor	11
2.4.1.	Perfiles de consumo.....	11
2.4.2.	Respuesta del consumidor	12
2.5.	Discusión.....	15
3.	Diseño de estrategia de gestión de demanda.....	17
3.1.	Caso de estudio.....	17
3.2.	Planteamiento del problema	21
3.3.	Metodología propuesta	22
3.4.	Simulador de consumo	26
3.4.1.	Generación de consumos base.....	27
3.4.2.	Generación de consumos con respuesta del consumidor al DSM	31
3.4.3.	Estructura del simulador.....	36
3.4.4.	Cálculo del factor de variación de consumo.....	37
3.4.5.	Generación de semáforos	37
3.4.6.	Generación de otros consumos	37
3.5.	Modelo de respuesta del consumidor	38
3.5.1.	Modelo difuso tipo Mamdani	38
3.6.	EMS con modelo de respuesta del consumidor.....	41
3.7.	Discusión.....	42

4.	Implementación.....	43
4.1.	Datos disponibles	43
4.2.	Simulador	44
4.2.1.	Consumo base.....	44
4.2.2.	Respuesta del consumidor	48
4.2.3.	Factor de variación de consumo	51
4.3.	Modelo difuso	53
4.4.	Implementación al EMS.....	59
4.5.	Pruebas en el optimizador del EMS	60
4.5.1.	Configuración de las pruebas	60
4.5.2.	Resultados	61
5.	Conclusiones y recomendaciones	65
5.1.	Trabajo futuro.....	66
6.	Bibliografía	67
A.	Anexo: Encuestas.....	71
A.1.	Encuesta de consumo	71
A.2.	Semáforos presentados a la comunidad.....	72
B.	Anexo: Herramientas usadas en el desarrollo	73
B.1.	Cadenas de Markov	73
B.1.1.	Selección de cantidad de estados.....	74
B.2.	Algoritmos genéticos.....	74
B.3.	Algoritmo <i>k-means</i>	75
B.4.	Redes Bayesianas	76
B.4.1.	Algoritmo EM	76
B.5.	Modelo difuso tipo Mamdani	77
C.	Anexo: Resultados	79
C.1.	Modelos tipo Mamdani	79
C.2.	Pruebas sobre el EMS.....	81

Índice de Tablas

Tabla 1. Componentes de la micro-red [35].....	18
Tabla 2. Uso típico de los artefactos encuestados [41]	32
Tabla 3. CPT para la probabilidad del estado	34
Tabla 4. CPT para la probabilidad de variación de estado	34
Tabla 5. Salidas posibles de la red Bayesiana	35
Tabla 6. Mediciones de consumo disponibles.....	43
Tabla 7. Encuestas disponibles.....	44
Tabla 8. Cantidad máxima de estados para cada cadena de Markov	45
Tabla 9. Medidas de verificación de los consumos base.....	46
Tabla 10. Valores de la CPT del televisor para la comunidad	49
Tabla 11. Errores de validación de modelos tipo Mamdani para el escenario 1	55
Tabla 12. Errores de validación de modelos tipo Mamdani para el escenario 2	56
Tabla 13. Errores de validación para la <i>lookup table</i> vs. Mamdani	58
Tabla 14. Resumen de costos del combustible.....	63

Índice de Figuras

Figura 1. Arquitectura básica de una micro-red [3]	5
Figura 2. Curvas de demanda objetivo del DSM [14].....	7
Figura 3. Demanda antes y después de comprar cargas a un usuario [19].....	10
Figura 4. Curva típica de demanda [32]	13
Figura 5. Simulación sobre datos de consumos reales en red Iraní [35]	14
Figura 6. Esquema del modelo de respuesta ante el DSM [36]	14
Figura 7. Modelación Difusa Propuesta en [37].....	15
Figura 8. Plano de casas en Huatacondo	18
Figura 9. Diagrama del EMS instalado en Huatacondo	19
Figura 10. Semáforo indicativo para gestión de demanda	20
Figura 11. Diagrama de la propuesta.....	23
Figura 12. Propuesta a implementar	25
Figura 13. Pasos a seguir para el desarrollo del simulador de consumo	26
Figura 14. Consumo medido de un día para una casa	27
Figura 15. Realización de transiciones.....	30
Figura 16. Esquema para la generación de datos con cadenas de Markov	31
Figura 17. Grafo de la red Bayesiana propuesta para las encuestas.....	33
Figura 18. Estructura del simulador	36
Figura 19. Conjuntos difuso para la estimación de variación de consumo [37]	38
Figura 20. Pasos a seguir para la obtención del modelo	41
Figura 21. Pasos a seguir para la incorporación al EMS.....	41
Figura 22. Agrupaciones obtenidas para una casa	45
Figura 23. Consumo medio medido y generado para la comunidad	47
Figura 24. Consumo con respuesta al DSM para 2 escenarios	50
Figura 25. Realización de factores ρ_L para 2 casos	51
Figura 26. Factores ρ_L por color obtenidos por el valor medio	52
Figura 27. Ejemplo de conjuntos difusos para la hora	53
Figura 28. Ejemplo de conjuntos difusos para la respuesta ρ_L	54

Figura 29. Factores ρ_L por color obtenidos con modelos tipo Mamdani.....	56
Figura 30. Factores ρ_L por color obtenidos con modelos <i>lookup table</i>	57
Figura 31. Salidas de modelos tipo Mamdani y de la media para el conjunto de validación	58
Figura 32. Factores de desplazamiento mínimo y máximo esperados	59
Figura 33. Desplazamientos deseados por el EMS para un día con potencia eólica.....	61
Figura 34. Operación de la micro-red para el escenario 2.....	62
Figura 35. Direcciones de razonamiento [44]	76
Figura 36. Esquema básico de un sistema difuso [53]	77
Figura 37. Métodos de defusificación [52].....	78
Figura 38. Conjuntos difusos hora y factor de respuesta para escenario 1	80
Figura 39. Conjuntos difusos hora y factor de respuesta para escenario 2	80
Figura 40. Factores S_L para un día sin potencia eólica	81
Figura 44. Operación de la micro-red en el escenario 1 con potencia eólica.....	82
Figura 46. Operación de la micro-red en el escenario 1 sin potencia eólica.....	82
Figura 47. Operación de la micro-red en el escenario 2 sin potencia eólica.....	83

1. Introducción

A lo largo de todo Chile existen cerca de 79 comunidades aisladas eléctricamente, ya sea por dificultades técnicas y/o económicas, que cuentan con el potencial para la instalación de una micro-red [1]. Así, las micro-redes surgen como una solución para que los pobladores tengan acceso a la electricidad, y con esto, a servicios y comodidades básicas. Las micro-redes son entendidas como sistemas de distribución eléctrica que contienen recursos energéticos distribuidos (*Distributed Energy Resources – DER*), como la generación, almacenamiento y cargas, que pueden ser controlados y coordinados [2]. Las unidades generadoras consisten en la generación por energías renovables no convencionales (ERNC), así como de generadores diésel; esto porque las ERNC por sí mismas tienen una alta variabilidad que no permite proveer de energía confiablemente [3].

Para poder realizar el despacho de la energía mientras se cumple con criterios económicos, es que existe el *Energy Management System (EMS)* [4] o sistema de gestión de la energía, que busca un punto de operación óptimo de la micro-red. Una opción para optimizar la operación, es introducir alguna estrategia de *Demand Side Management (DSM)* [5] o gestión de la demanda, cuyo objetivo es lograr cambiar los patrones de consumo de los consumidores, mediante algún tipo de indicación o incentivo, con el fin de lograr una mejor utilización de los recursos [6].

Este es el caso de Huatacondo, una comunidad aislada del Norte Grande de Chile, con cerca de 70 habitantes permanentes. Cuenta con generación solar y eólica. Esta micro-red tiene un DSM consistente en semáforos indicativos, en que para cada bloque horario se muestra una luz que indica si los usuarios deben aumentar, mantener o disminuir su consumo, esto en base a resultados del proceso de optimización realizado por el EMS instalado.

Si bien las señales mostradas por el semáforo tienen un significado intuitivo, no se tiene una cuantificación de la respuesta que generan sobre los usuarios, por lo que este conocimiento no se incorpora al proceso de optimización. Modelar la respuesta es de interés para tener una estimación del rango real en el que responderán los usuarios, con el fin de generar una gestión de demanda adecuada sobre ellos, y así, optimizar el funcionamiento de la micro-red.

En el marco de esta memoria, surgieron visitas en terreno a las comunidades aisladas de El Romeral (región de Coquimbo) y Huatacondo (región de Tarapacá), con lo que se pudo tener un contacto más cercano y un conocimiento más amplio del rol y la importancia de las micro-redes en poblados aislados.

1.1. Objetivos

Los objetivos para este trabajo se detallan a continuación.

1.1.1. Objetivo general

- Diseñar una estrategia de gestión de demanda que considere la inclusión de un modelo de respuesta de los usuarios.

1.1.2. Objetivos específicos

- Desarrollar un simulador de consumos que considere casos con y sin respuesta de los usuarios ante la estrategia de gestión de demanda, a partir de datos medidos y encuestas realizadas, para la generación de datos.
- Obtener un modelo de respuesta de los consumidores, que permita una estimación de esta respuesta ante la señal de gestión lumínica indicada y la hora del día.
- Diseñar el modelo que se incorpora al sistema de gestión de la energía a partir del modelo obtenido, para incluir la respuesta de los consumidores.
- Cuantificar los beneficios de implementar el método propuesto en el sistema de gestión de la energía.

1.2. Alcances

En esta memoria, se buscará integrar la respuesta de los usuarios al sistema de gestión de la energía, para poder realizar una gestión de la demanda que mejore el funcionamiento, en términos económicos, de la micro-red aislada de Huatacondo. Para el desarrollo, se utilizarán tanto datos históricos de consumo, como encuestas de consumo realizadas a la comunidad ante distintas indicaciones del DSM.

El sistema de DSM instalado en la comunidad consiste en señales luminosas indicadas por un semáforo. Este sistema no tiene incentivos económicos para los usuarios, por lo que presenta dificultades para la cuantificación de la respuesta. Así, se supondrá que la respuesta de los usuarios depende de la hora y color indicado.

Con estos datos, y dada la falta de datos con DSM, se desarrollará un simulador con entradas correspondientes a la hora y el color de la luz, utilizando cadenas de Markov y redes Bayesianas, que permitan la simulación de datos representativos de la comunidad suficientes como para la obtención de un modelo que estime esta respuesta. Las salidas de este modelo serán utilizadas para modificar las entradas al EMS que consideren la respuesta de los usuarios en el proceso de optimización. No se considera la modificación del EMS ya programado.

La implementación de la propuesta será realizada en MATLAB, utilizando las herramientas de optimización y modelación difusa provistas por el software, entre otras. Además, se usará un *toolbox* de redes Bayesianas desarrollado por K. Murphy [7] y que implementa los algoritmos necesarios para el entrenamiento de la red.

Finalmente, pruebas finales con la inclusión del modelo serán realizadas sobre un optimizador fuera de línea del EMS [8] al que se le proveerán entradas que incluyen la respuesta esperada de los usuarios.

1.3. Estructura de la memoria

La estructura principal de esta memoria se divide en 4 capítulos, explicados brevemente a continuación.

En el Capítulo 2 se realiza una revisión bibliográfica de conceptos relativos a micro-redes, que incluyen sistemas de gestión de la energía (*Energy Management System – EMS*) y especialmente estrategias de gestión de la demanda (*Demand Side Management – DSM*) propuestos en la literatura. Finalmente, se dan a conocer métodos de simulación y estimación de la respuesta esperada de los usuarios ante distintos DSM.

En el Capítulo 3 se explica el caso particular de estudio, dando a conocer la problemática existente y estableciendo una propuesta para resolverla. Se explica el desarrollo metodológico, introduciendo los conceptos y estrategias a utilizar en la implementación.

En el Capítulo 4 se implementa la metodología propuesta para el caso de estudio específico. Se realizan pruebas para distintos escenarios sobre un simulador del EMS, buscando determinar los posibles beneficios de implementar la estrategia propuesta. También se realiza un análisis de estos resultados y se comparan con otros métodos.

Finalmente, en el Capítulo 5 se concluye sobre los resultados obtenidos en base a los objetivos, destacando las contribuciones realizadas y presentando mejoras al trabajo futuro que permitan extender los alcances de la metodología propuesta.

2. Revisión bibliográfica

En esta sección se realiza una breve revisión de conceptos básicos de micro-redes y sobre sistemas de gestión de la energía, para luego enfocarse en el estado del arte de estrategias de gestión de la demanda, con distintas metodologías abordadas en la literatura y, finalmente modelos que buscan estimar la reacción que tendrán los consumidores ante las señales de gestión enviadas por el sistema.

2.1. Micro-redes

En Chile y el mundo existen diversas comunidades que no se encuentran conectadas a los grandes sistemas energéticos. Esto se debe en gran medida a las dificultades que existen para hacer llegar líneas de transmisión a estos poblados, por su difícil acceso, y a la poca viabilidad económica que esto representaría.

Generalmente estos pueblos cuentan con generadores diésel para la generación de energía eléctrica que, si bien tienen como características un bajo costo de inversión y una alta confiabilidad, tienen una baja eficiencia, altos costos de mantenimiento y principalmente de operación [9], estando limitados a unas pocas horas de electricidad al día. Es en estas comunidades donde genera interés la instalación de micro-redes aisladas, para aumentar el rango horario y disminuir los costos de funcionamiento, agregando como unidades de generación energías renovables no convencionales (ERNC), como son la energía solar y eólica, entre otras, que reducen la contaminación generada por las fuentes de energías fósiles.

Una micro-red es entendida como un sistema de distribución eléctrica que contiene recursos energéticos distribuidos, como la generación, almacenamiento y cargas, que pueden ser controlados y coordinados [2]. Estas micro-redes pueden estar conectadas a los grandes sistemas de energía con la posibilidad de comprar y vender energía según se requiera, o también pueden trabajar en un modo aislado (o isla), como se expone en [10], en que toda la generación, distribución y consumo se desarrolla en el área local, siendo un desafío gestionar los recursos limitados.

En la Figura 1 se puede observar un esquema básico de una micro-red, en este caso conectada a la red, en que se pueden identificar las cargas, unidades de generación y un sistema gestor de la energía. Existen interruptores de separación en casos críticos, ya sea para desconectarse de la red por motivos de seguridad, o para desconectar las cargas. En este diagrama, se puede ver que las líneas A y C tienen cargas y unidades de generación (eléctrica y termal), mientras que la B sólo cuenta con cargas, por lo que eventualmente podría ser desconectada.

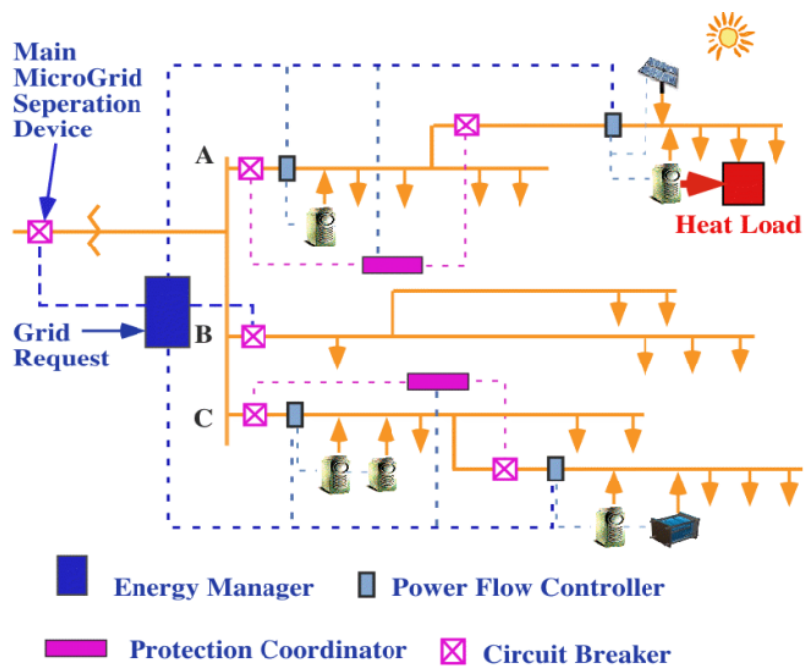


Figura 1. Arquitectura básica de una micro-red [4]

En [11] se describen tres jerarquías de control para una micro-red:

- **Control primario**, también conocido como local o interno, es de respuesta rápida y se encarga de regular el voltaje, la corriente y la frecuencia de la micro-red, además de realizar un balance de potencia entre la generación y la carga.
- **Control secundario**, gestionado por el sistema de gestión de la energía (*Energy Management System – EMS*), que se encarga de la operación de la micro-red en términos de seguridad, confiabilidad y económicos. Para esto, se busca la programación óptima del encendido y apagado de las unidades generadoras y su despacho, tales que se cumplan ciertos objetivos de operación de la micro-red. En micro-redes aisladas, este es el control de mayor jerarquía.
- **Control terciario**, de un nivel más alto, más lento que los anteriores, y que coordina distintas micro-redes interconectadas, comunicándose con los EMS de las distintas redes.

2.2. Sistema de gestión de la energía (EMS)

La generación utilizando ERNC, si bien tiene la ventaja de ser limpia y con un bajo costo de producción, tienen los inconvenientes de requerir una alta inversión inicial, y más importante aún, de que no son una fuente confiable de energía, principalmente por su disponibilidad variable [3]: por ejemplo la energía solar no está disponible en horarios nocturnos, mientras que la eólica tiene un comportamiento más bien estocástico, de difícil predicción e intermitente.

Es por esto que se hace necesario un sistema que gestione la energía (EMS) en micro-redes, especialmente si éstas son aisladas. El EMS es un sistema computacional que se utiliza para programar y optimizar la gestión de la potencia distribuida, los sistemas de almacenamiento y cargas de la micro-red. Este sistema puede utilizar información histórica y de las capacidades de

cada unidad, además de agregar restricciones y requerimientos para realizar la programación y minimizar los costos de operación [12], que incluyen factores que dependen de la micro-red en específico.

Entre sus funciones específicas están [4]:

- Definir los puntos de operación de potencia y voltaje para los sistemas de generación.
- Cumplir con la demanda de las cargas.
- Minimizar emisiones y pérdidas del sistema.
- Maximizar la eficiencia del sistema.
- Gestionar la conexión y desconexión de la micro-red a la red.

Además de las funciones ya mencionadas, y dependiendo de los objetivos del sistema, el EMS puede enviar consignas a los consumidores o cargas [11], de forma tal que exista una gestión de la demanda, en el marco de optimizar la operación.

2.3. Gestión de la demanda (DMS)

Uno de los factores que sería de interés controlar para optimizar el funcionamiento de la micro-red, es la demanda de las cargas de los usuarios. Es por esto que surge a fines de los años 70 el concepto de sistema de gestión de demanda (*Demand Side Management – DSM*), y se refiere al planeamiento, implementación y monitoreo de diversas actividades que están diseñadas para actuar deliberadamente sobre los patrones de consumo del consumidor, con el fin de lograr cambios deseados en su curva de consumo que cumpla con una mejor utilización de los recursos [6].

El fin del DSM en micro-redes es balancear la demanda con el suministro, modificando el consumo de los usuarios en el tiempo con tal de optimizar el funcionamiento del sistema y minimizar costos. De esta forma, el esfuerzo es realizado por los consumidores, es decir, el lado de la demanda. En micro-redes esta función es crítica, en especial si se encuentra en modo aislado, dado la limitación de los recursos disponibles y presenta un desafío mayor, porque en estos sistemas no se puede aplicar la ley de los grandes números, a diferencia de los grandes sistemas energéticos.

En la Figura 2, se pueden observar seis objetivos de curvas de demanda que se busca lograr con el DSM [6]:

- **Recorte de Picos (*Peak Clipping*)**: Consiste en reducir los *peaks* o valores máximos de la curva de consumo, con el fin de no tener una sobrecarga en el sistema en dichos horarios y así poder cumplir con la demanda.
- **Llenado de Valles (*Valley Filling*)**: Busca generar cargas fuera de los *peaks* de consumo y rellenar con cargas los horarios valle. Esto puede ser útil cuando económicamente es mejor proveer más energía.
- **Movimiento de Cargas (*Load Shifting*)**: Involucra el movimiento de cargas de los *peaks* a periodos que están fuera de los *peaks*, cambiando el horario en que los usuarios utilizan

sus artefactos eléctricos. Con esto se busca generar una curva de demanda con menos variaciones entre sus valores extremos.

- **Curva Flexible de Carga (*Flexible Load Shaping*):** Asociado a la confianza del suministro, en que se estima la demanda incluyendo las acciones del DSM, y se obtiene el funcionamiento óptimo para el lado del suministro. De esta forma, la curva de consumo se considera flexible y los usuarios pueden modificar su consumo a cambio de diversos incentivos.
- **Aumento Estratégico de Cargas (*Strategic Load Growth*):** Es un aumento generalizado en la demanda, resultado de un aumento en las ventas del mercado de cargas, y va más allá de la estrategia de *Valley Filling*. Puede estar motivado por una reducción de combustibles fósiles, baja eficiencia en la generación y el reemplazo de fuentes térmicas por artefactos eléctricos, principalmente.
- **Eficiencia Energética (*Strategic Conservation*):** Es una disminución de la demanda, resultado de una disminución en las ventas del sector energético o resultado de políticas públicas, e involucra un cambio en los patrones de consumo de los usuarios. Para lograrlo, se deben identificar las acciones de conservación que se pueden dar naturalmente en los usuarios y diseñar políticas que las fomenten y aceleren. Puede estar motivado cuando el consumo supere a la generación instalada.

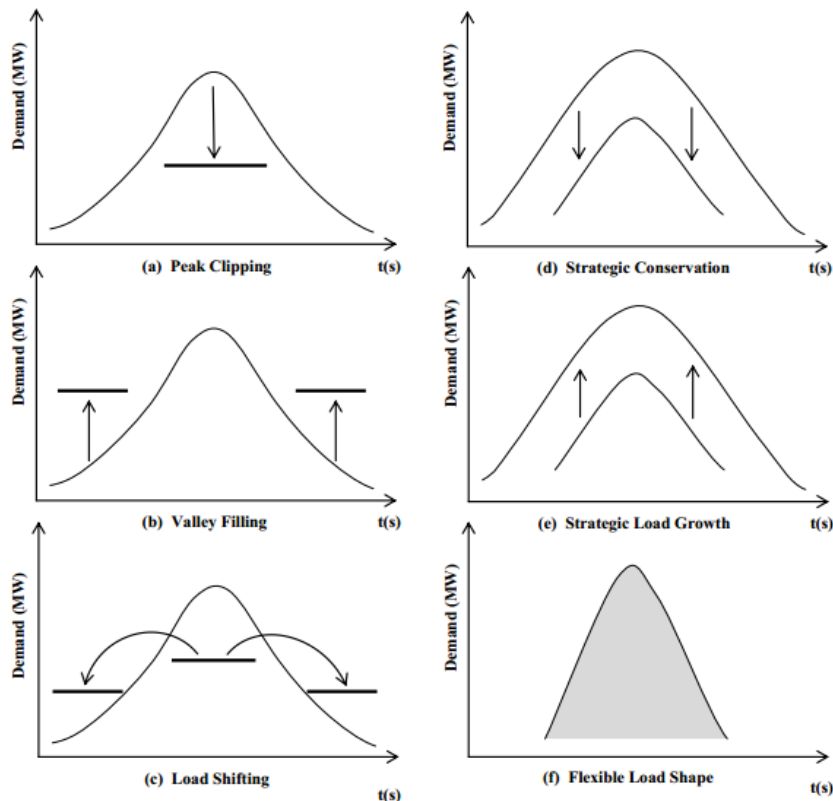


Figura 2. Curvas de demanda objetivo del DSM [15]

Las primeras cuatro categorías son a corto-plazo y se pueden categorizar como estrategias de respuesta de la demanda (*Demand Response – DR*) [13], que tiene como objetivo la modificación

intencional a corto plazo de los patrones de consumo de los usuarios, con el fin de variar o disminuir la demanda instantánea de energía [14]; mientras que las dos últimas son estrategias a largo plazo, centradas en variar hábitos de consumo permanentemente.

Según [16], el DSM debe cumplir con ciertos criterios de diseño:

- Generar una interacción entre el usuario y la red, de forma que los usuarios ajusten su consumo eléctrico en respuesta a las señales de gestión.
- Cambiar los hábitos de consumo para optimizar la gestión.
- Proveer información al usuario de su uso histórico y actual de electricidad, con el fin de asistirlo en la toma de decisiones.
- Considerar el dimensionamiento del consumo y los tipos de carga en el diseño del sistema.
- Resolver los problemas ambientales y de recursos, como es disminuir las emisiones y los costos de generación.
- Estar diseñado para satisfacer diversas demandas y responder a varios factores.

Las acciones que puede ejercer el DSM sobre las curvas de demanda, además de las características de los usuarios, depende del tipo de cargas sobre las cuales se quieren actuar, ya que no todas responden de la misma forma a las distintas estrategias. En [17] se describen cuatro tipos de cargas para micro-redes:

- **Críticas:** Aquellas cuya demanda debe cumplirse sin excepciones en todo momento, por ser en extremo importantes para el consumidor.
- **Controlables:** Las que, aunque tienen un momento de preferencia para ser utilizadas, son flexibles en su magnitud, pudiendo variar su horario de uso según la gestión que se realicen sobre ellas.
- **Sensibles al precio:** En que su utilización depende de forma directa del precio de la energía eléctrica, contando con un umbral de precio sobre el cual se interrumpe su funcionamiento.
- **Termales:** Aquellas que requieren energía térmica para su funcionamiento, como son para el calentamiento de aguas, y puede ser provista por fuentes fósiles, solares o eléctricas.

En base a esta clasificación, es sobre las cargas controlables y sensibles al precio en las que puede actuar el DSM, dependiendo de la estrategia que sea utilizada, las cuales se nombrarán en la siguiente sub-sección.

2.3.1. Estrategias de DSM

Las estrategias de gestión de demanda se pueden dividir en dos grandes grupos, con un alto grado de complementariedad entre ambos [5]:

2.3.1.1. *Basadas en el incentivo*

En esta estrategia, los consumidores reciben incentivos monetarios por reducir su consumo en períodos en que la red tiene una alta demanda. Dentro de esta clasificación cabe destacar:

- **Control directo de cargas**

El control directo de carga (*Direct Load Control – DLC*) consiste en que los usuarios acepten que ciertos aparatos puedan ser desconectados de forma remota y automática por el sistema de gestión de demanda, siendo recompensados con pagos. Este enfoque tiene el inconveniente de requerir la modificación de ciertos artefactos para que sean *cargas inteligentes*, con los consecuentes costos asociados, además de la poca aceptación que se puede esperar.

En [18] se propone un sistema basado en el incentivo con DLC, en que un controlador central de la micro-red (*Micro-Grid Central Controller – MGCC*), además de manejar las unidades de generación, puede controlar ciertas cargas, conectándolas y desconectándolas de forma automática según sea necesario para cumplir con la optimización del sistema. Las cargas están comunicadas inalámbricamente al MGCC, que las puede reconocer de acuerdo a su perfil de consumo y se controlan mediante un interruptor inalámbrico.

En [19] se establece que la calefacción, ventilación y aire acondicionado (*Heating, Ventilation and Air Conditioning – HVAC*), calentadores de agua y los sistemas de almacenamiento de energía termal pueden estar controlados bajo DLC, teniendo en cuenta diversas restricciones, como las relacionadas con la economía, confort y expectativas del consumidor. Se consideran simulaciones para un sistema típico de distribución en un área residencial de España y controlando únicamente las cargas HVAC. Para esto, se realiza una modelación de las cargas mencionadas, con tal de calcular los consumos de estas para determinadas referencias dadas por el usuario, y se simula sobre datos reales. Concluye que con esta estrategia se puede lograr disminuir el consumo en horas pico, ahorrando energía y dinero, además de mejorar la calidad del suministro.

- **Cargas interrumpibles**

Los usuarios acuerdan en reducir su consumo cuando la red lo requiera, por lo cual reciben pagos. De no cumplir con el convenio, serán penalizados económicamente. Esta estrategia es utilizada principalmente con grandes consumidores de energía, como pueden ser empresas o fábricas, que tienen una alta influencia en la demanda de los sistemas de potencia.

En [20] se realiza una simulación para un sistema real de potencia en que se gestionan cargas interrumpibles (*Interruptible Load Management – ILM*). Define diversos tipos de contratos dependiendo del mercado a los que se aplique y la duración por la cual debe aplicar el ILM. Se tienen además límites del total de cargas sujetas a interrupción, intervalos entre dos interrupciones y duración total de las mismas. Como resultados simulados, presenta beneficios económicos para ambas partes, logrando una disminución del consumo, como se puede observar en la Figura 3.

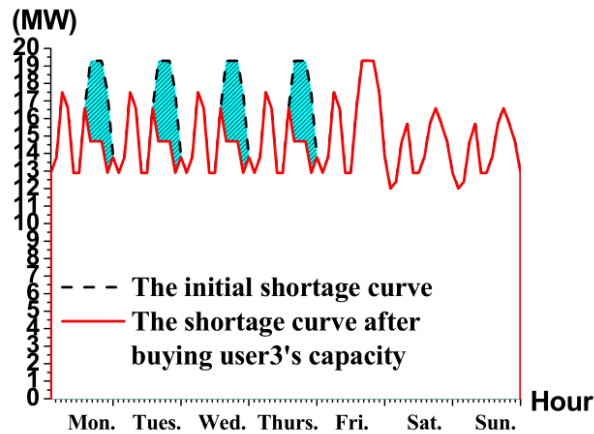


Figura 3. Demanda antes y después de comprar cargas a un usuario. Donde *user3* es gran usuario del mercado eléctrico [20]

Esta solución asume que estos grandes consumidores tienen un comportamiento determinista y totalmente predecible, buscando disminuir su consumo para así minimizar sus costos; esto no considera variaciones estocásticas propias del comportamiento humano en la toma de decisiones finales.

2.3.1.2. Basadas en tarifas según el tiempo

Esta estrategia se refiere a que el usuario recibe señales que indican la tarificación para la energía en cierto momento, logrando así que cuando la red tiene una alta demanda, el precio aumenta, mientras que en el caso contrario se tienen precios bajos.

- **Tarifas por tiempo de uso**

En la estrategia por tiempo de uso (*Time of use – TOU*) se tiene una programación tarifaria fija, en que los periodos de alta demanda tienen precios mayores, como pueden ser ciertas horas del día o ciertos meses del año. Esta metodología es la más utilizada para realizar gestión de demanda [5], en que se asume que la demanda tiene un comportamiento altamente periódico, y por ende se puede mantener un programa de precios fijo. Esto último es aplicable en grandes sistemas energéticos; sin embargo, en micro-redes esto no es así, ya que se tiene una alta variabilidad en las curvas de demanda, porque las acciones individuales tienen una mayor influencia en el consumo total.

En [21] se analiza un experimento voluntario residencial de un sistema con gestión de la demanda basada en TOU, en que se envía a los consumidores una señal del precio de la energía según un calendario definido, concluyendo que este método puede lograr un movimiento de cargas significativo desde los *peaks* a horarios fuera de *peak*. Además, se determina que cargas que resultan más fáciles de cambiar en horario de uso, son las relacionadas con la cocina, lavado de platos, de ropa y secado, por lo que corresponderían a cargas controlables.

- **Tarificación en tiempo real**

En la tarificación en tiempo real (*Real-time Pricing – RTP*), el sistema envía señales que reflejan el precio de mercado de la electricidad a los consumidores y el usuario es quien

finalmente decide, en función de sus capacidades y necesidades, cómo variará su consumo. Esta variación en el precio puede ser en tiempo real o darse a conocer con cierta anticipación, con el fin de que el consumidor pueda programarse.

Los principales problemas de esta estrategia son la poca información de los usuarios respecto a los precios [22] y la poca efectividad en la respuesta, dado que es una acción manual. Para resolver estos problemas, en [23] se establece un sistema automático residencial que realiza una predicción con auto-regresores del precio que serán enviados bajo la estrategia RTP, y tiene en cuenta las preferencias del usuario, como la comodidad y disposición a pagar, con tal de realizar una programación de los artefactos en base a los requerimientos específicos del usuario. Se presentan simulaciones hechas con datos reales en que se obtiene una disminución de los costos para el usuario, reduciendo los pagos en hasta un 25% (dependiendo de la anticipación con que se informen los precios de la energía) respecto a un caso sin control de demanda.

Tanto las estrategias por incentivos como por precios traen beneficios económicos para los usuarios como una forma de hacerlos participar activamente en la red. Sin embargo, no siempre esto es posible por temas de infraestructura, costos o por las características propias de la población. Utilizando una estrategia distinta a los grandes grupos mencionados, en [24] se describe un sistema de gestión de demanda basado en relojes de 24 horas, indicando para cada período horario la acción que deben tomar los consumidores mediante un código de colores. En este sistema no hay incentivos económicos, sin embargo, la población ha sido educada respecto al funcionamiento del DSM y se espera que las acciones sean en búsqueda del bien común.

Se espera que los usuarios sean tengan una respuesta ante la gestión de demanda, y es de interés tener una cuantificación de esta respuesta. En la siguiente sección se verán distintas estrategias utilizadas en la literatura para modelar el comportamiento de los usuarios ante el DSM.

2.4. Modelación del consumidor

Un aspecto importante a considerar para las estrategias de gestión de demanda, es la modelación de la respuesta del consumidor ante el DSM. Esto permite seleccionar la señal de gestión (como puede ser el precio) que genere una respuesta deseada por el EMS.

Junto con lo anterior, se tiene que la realización de pruebas y obtención de datos es un proceso lento, requiriendo en general de varios días para obtener resultados concluyentes, y además afecta a las personas de forma directa. Para superar esto, se puede optar por la realización de simuladores que permitan generar datos representativos del área a estudiar, con los que se pueda trabajar para probar metodologías y distintas estrategias de control, sin interferir con la vida diaria de los usuarios.

2.4.1. Perfiles de consumo

Para la generación de consumos existen principalmente dos enfoques: el generar actividades de los residentes a las que se puedan asociar consumos, y el utilizar mediciones de potencia a las que se puedan ajustar modelos.

La metodología propuesta en [25] define perfiles de consumo propios de cada artefacto que se encuentra en una casa. Para aquellos artefactos en los que su uso depende de si son encendidos o no por una persona, define reglas de utilización, que tienen distribuciones de probabilidades asociadas que tratan de emular los comportamientos de los usuarios. Finalmente propone la combinación de perfiles de consumo fijos a los cuales se les aplica variaciones dadas probabilísticamente.

En [26] se consideran tres tipos de viviendas, de consumo bajo, medio y alto. En base a encuestas que contienen promedios de las aplicaciones (cargas) que tienen las viviendas, sus consumos y tiempos de uso mensuales, se asignan a los distintos tipos de viviendas cargas y usos, con variaciones en torno a los promedios y se generan utilidades aleatorias que cumplan con los valores medios. Finalmente, compara los datos generados con mediciones reales, obteniendo buenos resultados en la energía consumida y potencia *peak*.

La generación de un simulador de consumo en base a encuestas de consumo realizadas a viviendas se utiliza en [27]. Con los datos generados, se comparan distintas distribuciones de probabilidad por minuto para la potencia consumida, resultando ser las distribuciones gamma, log-normal y normal las que mejor se ajustan a los datos del simulador. Con esto, se pueden generar datos aleatorios representativos por instante de muestreo, pero no necesariamente en las transiciones.

En [28] se generan consumos mediante el encendido y apagado de artefactos, obtenido a partir de probabilidades de uso en base a la temporada, hora, frecuencia de uso y energía consumida en el día. Los datos generados mantienen las características de consumo energético y potencia media en comparación a mediciones reales. Utiliza el simulador para estudiar el impacto de una estrategia DSM de control directo de cargas, obteniendo recortes de *peaks* desde un 7% a un 61%, dependiendo de la agresividad y restricciones impuestas a la gestión de demanda.

En [29] se utilizan cadenas de Markov para la generación de curvas de demanda de iluminación residencial. Las cadenas generan patrones de ocupación de los residentes considerando tres estados posibles: ausente (fuera de la casa), activo (realizando una actividad dentro de la casa), e inactivo (durmiendo). Las probabilidades de transición varían dependiendo de la hora del día en que se esté. En base a estos estados se modela la demanda energética debida a la iluminación, en función del estado y de la luz natural. Extendiendo los resultados anteriores, en [30] se generan patrones de actividad para los residentes de una vivienda, como son el cocinar, lavar, ver televisión, utilizar el computador, entre otros, permitiendo la asociación de potencias típicas de los artefactos involucrados. Estos métodos requieren llevar un registro de las actividades realizadas por los habitantes, lo que no está disponible generalmente, además que puede resultar invasivo para los residentes.

2.4.2. Respuesta del consumidor

Un aspecto importante a considerar para la optimización del sistema, es caracterizar la respuesta de los consumidores ante el DSM, con el fin de realizar predicciones que se ajusten de mejor manera al consumo real, dadas las señales de gestión.

En [31] se establece un modelo de respuesta de consumidor para grandes demandantes de energía, con un DSM basado en tarifas. Este modelo de programación lineal considera que los consumidores son racionales y siempre buscan maximizar sus beneficios, de forma que se busca minimizar una función de costos que incluye el costo de la energía, el consumo y la utilidad, todo por bloques horarios, restringiendo la energía mínima y máxima demandada y los incrementos y decrementos del consumo entre dos bloques horarios consecutivos. Este enfoque se puede considerar válido sólo para grandes empresas que efectivamente buscan maximizar sus beneficios, ya que no tiene en cuenta hábitos.

Existen otras estrategias basadas en agentes, que buscan simular computacionalmente las acciones e interacciones entre individuos, como la expuesta en [32], en que se considera al grupo familiar como un agente, que cambia sus actividades cotidianas, con cierta probabilidad, en base al precio de la energía. Para esta modelación se hace necesario contar con encuestas a la población que permitan modelar su comportamiento. También describe un modelo basado en redes neuronales (*Neural Networks – NN*) que, en base a sets de entrada/salida, permita la modelación. Como entradas relevantes para determinar el comportamiento, se incluyen el precio, clima, día (hábil o fin de semana), demanda anterior y el momento del día.

Otra alternativa es la utilización de modelos económicos, como la utilización de la curva de demanda, como la de la Figura 4, utilizando una linealización de esta curva en torno a un punto de operación, para obtener la elasticidad ante las variaciones del precio de la energía eléctrica [33], [34], [35].




Figura 4. Curva típica de demanda [33]

En [36] se utiliza la estrategia anterior en una simulación que aplica sobre datos reales de la red de potencia Iraní la respuesta de los consumidores, logrando disminuir los *peaks* de consumo en distintos escenarios de cargas afectadas e incentivos aplicados. En la Figura 5 se ve un resultado con un precio menor en horario fuera de las horas punta y mayor en las horas punta; *d0* es el consumo base y *final* es el consumo con la gestión de demanda. Sin embargo, la problemática está en la determinación de la curva de demanda, que debe ser aproximada.




Figura 5. Simulación sobre datos de consumos reales en red Iraní [36]

En [19] no se modelan a los consumidores directamente, sino que se modelan las cargas sujetas a responder automáticamente ante las señales de gestión (relacionadas con la climatización), pero cumpliendo con ciertos estándares dados por los consumidores, de tal forma que no afecten su confort significativamente y reduzcan los costos asociados.

Sin embargo, estas estrategias consideran únicamente el precio de la energía como incentivo entregado y suponen que los usuarios siempre tratarán de minimizar sus costos.

En [37] se describe un modelo difuso para la estimación de la respuesta de los usuarios ante el precio de la energía, motivado principalmente por el uso de valores lingüísticos, cercanos a la lógica humana. Se agregan criterios socio-económicos (como los hijos, el capital y nivel social), ocupación de la residencia, incentivos, predicciones de consumo, la existencia de una situación extraordinaria y la hora del día, para determinar la variación del consumo del usuario y su nivel de motivación, cuyo esquema se puede apreciar en la Figura 6.

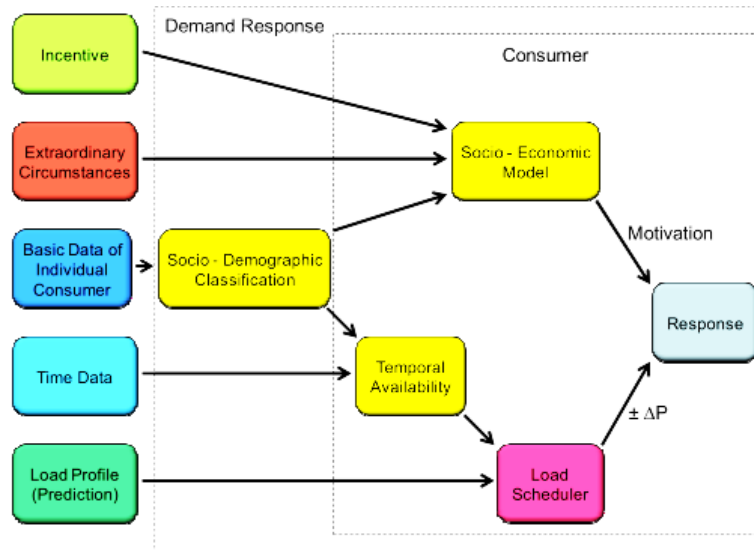


Figura 6. Esquema del modelo de respuesta ante el DSM [37]

El modelo, sin validar experimentalmente, se prueba con datos simulados, obteniendo las variaciones de potencia que se pueden lograr para cada instante.

Finalmente, en [38] se propone una modelación difusa tipo Mamdani para estimar la respuesta de la población en una comunidad rural ante las señales de los semáforos y sin incentivos económicos de ningún tipo. Se proponen como entradas al modelo el color de la luz del semáforo indicativo (verde, amarilla o roja) y la hora del día (mañana, tarde y/o noche), indicado en la Figura 7, para así estimar la variación en el consumo de la comunidad (baja, media y/o alta).




Figura 7. Modelación Difusa Propuesta en [38]

La modelación difusa tipo Mamdani es de interés para este caso dado el tratamiento lingüístico que da a la modelación.

2.5. Discusión

Para una micro-red aislada es de vital importancia un óptimo uso de los recursos disponibles, ya que no se puede acceder a la energía de fuentes externas. La gestión es realizada por el EMS, que incluye restricciones económicas y técnicas para optimizar el funcionamiento de la red.

Un punto importante es la predicción de la demanda, para estimar las capacidades de generación a utilizar. Si el sistema cuenta con recursos limitados, es deseable introducir el DSM, con estrategias a corto y largo plazo, para gestionar la demanda de los consumidores y reducir el consumo en horarios *peak* para trasladarlos a horarios en que la demanda sea menor, o reducir el consumo general, logrando una eficiencia energética.

La mayoría de los modelos que buscan modelar la respuesta de los usuarios, se centran en técnicas del DSM basadas en incentivos económicos y tarificación, modelando al usuario como un agente que busca maximizar sus beneficios, o analizando la elasticidad en su demanda ante variaciones en el precio. Sin embargo, estas estrategias no se pueden aplicar en redes que no integren factores monetarios como recompensa a los usuarios, por lo que el desafío en estos casos es lograr que los usuarios respondan ante señales de gestión por medio de la educación de la población para que tomen conciencia del cuidado de la energía.

El desarrollo de datos simulados de consumos, junto con simulaciones de las respuestas de los consumidores ante distintos incentivos, es ampliamente usado, como un método para el análisis de los beneficios e impacto de distintas estrategias de DSM. Esto permite probar distintas estrategias en un menor tiempo y sin generar molestias en la población. Sin embargo, muchas estrategias para la generación de consumos requieren de una elevada cantidad de datos, en algunos casos, detallados de las actividades diarias realizadas por los residentes, datos que pueden ser difíciles de conseguir y que se pueden aplicar para la generación de consumos en grandes ciudades, donde se aplican las leyes de los grandes números.

3. Diseño de estrategia de gestión de demanda

En esta sección se realiza el diseño de una estrategia de gestión de demanda para un caso de estudio particular, definiendo sus características de generación, el sistema de gestión de la energía (*Energy Management System* – EMS) y la estrategia de gestión de la demanda (*Demand Side Management* – DSM) particulares de este caso. Se identifica la problemática existente respecto al sistema de DSM, que consiste en una secuencia de luces que indica, mediante colores, qué respuesta se espera de los usuarios, ya sea aumentando, manteniendo o disminuyendo su consumo. Finalmente, se detalla la propuesta, indicando los conceptos y estrategias a utilizar.

3.1. Caso de estudio

La micro-red aislada en la cual se basa este trabajo está ubicada en la comunidad rural de Huatacondo, ubicada en la región de Tarapacá ($20^{\circ}55'36.37''$ S $69^{\circ}3'8.71''$ W) y desconectada del Sistema Interconectado del Norte Grande (SING) [8]. Esta comunidad tiene cerca de 70 habitantes permanentes, mientras que para distintas festividades, especialmente las religiosas, la población puede aumentar hasta las 300 e incluso 400 personas.

La ocupación de la comunidad está centrada principalmente en la agricultura, seguida por la minería. La edad de la población se concentra en adultos mayores jubilados, aunque también hay niños en la edad escolar; los jóvenes y adultos jóvenes generalmente emigran del pueblo en busca de completar su educación media y nuevas oportunidades. El clima de la zona es una combinación del desértico marginal de altura y estepa de altura [39], que se caracteriza por la presencia de precipitaciones y nubosidades en los meses de enero, febrero y marzo por el invierno boliviano, y escasa nubosidad el resto del año. En la Figura 8 se puede observar el plano de las viviendas de Huatacondo desarrollado en agosto de 2014. Cada una de las casas está numerada con motivos de identificación para ser asociadas a los datos que se obtienen. Alrededor de 25 familias viven permanentemente en el pueblo, por lo que gran cantidad de las casas que se pueden apreciar se encuentran desocupadas la mayor parte del año, siendo ocupadas principalmente en las fiestas.

Previo a la instalación de la micro-red, la comunidad contaba con 10 horas diarias de electricidad provista por un generador diésel. Actualmente, y gracias al proyecto de Electrificación Sustentable Cóndor (ESUSCON), desde el 2010 cuenta con una micro-red instalada por el Centro de Energía de la Universidad de Chile, que provee un servicio de 24 horas de electricidad al día utilizando paneles fotovoltaicos, una turbina eólica, un generador diésel y un sistema de almacenamiento de la energía. Como cargas del sistema, se cuentan una bomba de agua y los artefactos e iluminarias eléctricas de la población [8].

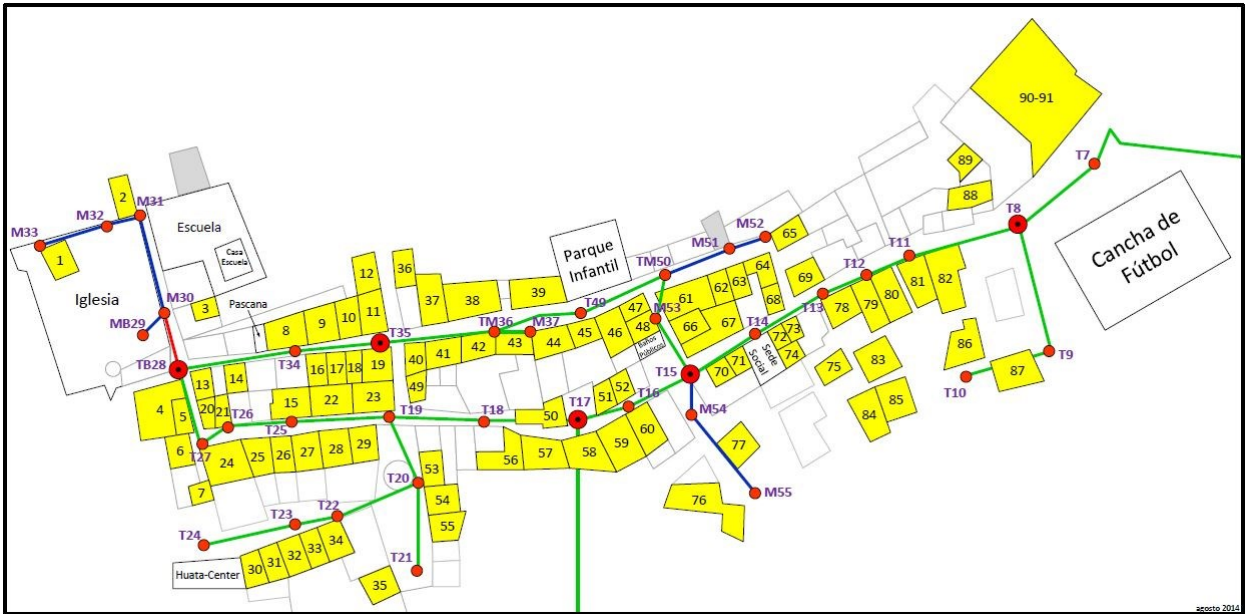


Figura 8. Plano de casas en Huatacocondo

Específicamente, esta micro-red cuenta con las unidades de generación y almacenamiento listadas en la Tabla 1.

Tabla 1. Componentes de la micro-red [8]

Parámetro	Valor
Potencia paneles fotovoltaico	24 [kW]
Potencia turbina eólica	5 [kW]
Potencia del banco de baterías	40 [kW]
Capacidad del banco de baterías	170 [kWh]
Potencia del generador diésel	10-150 [kW]

La micro-red cuenta con un sistema de gestión de la energía (EMS), descrito en [8], que se encarga de coordinar y optimizar la operación de las unidades de generación y cargas, minimizando costos de generación, potencias no suministradas, pérdidas y agua no suministrada. El tiempo de muestreo de este EMS es de 15 minutos, por lo que diariamente se tienen 96 datos por variable.

Como se aprecia en la Figura 9, las entradas al EMS son:

- Estimador del estado de carga de las baterías (E_{SOC})
- Predicciones de potencia solar máxima y mínima (P_{Smax} y P_{Smin})
- Predicciones de potencia eólica (P_E)
- Predicciones de los consumos eléctricos y de agua (P_L y W_C)
- Variaciones máximas y mínimas de consumo esperadas ante señales de gestión de demanda (S_{max} y S_{min})

- Condiciones iniciales de estado de carga (E_{SoC_i}), voltaje (V_I) y corriente (I_I) del banco de baterías, nivel del tanque de agua (V_{Tf_i}) y el estado (encendido o apagado) del generador diésel (B_{g_i}).

Por su parte, las salidas corresponden a:

- Referencia de potencia para el generador diésel (P_D)
- Potencia solar (P_S)
- Potencia del inversor (P_I)
- Señal binaria para la bomba de agua (B_P)
- Factor de desplazamiento de la demanda (S_L)

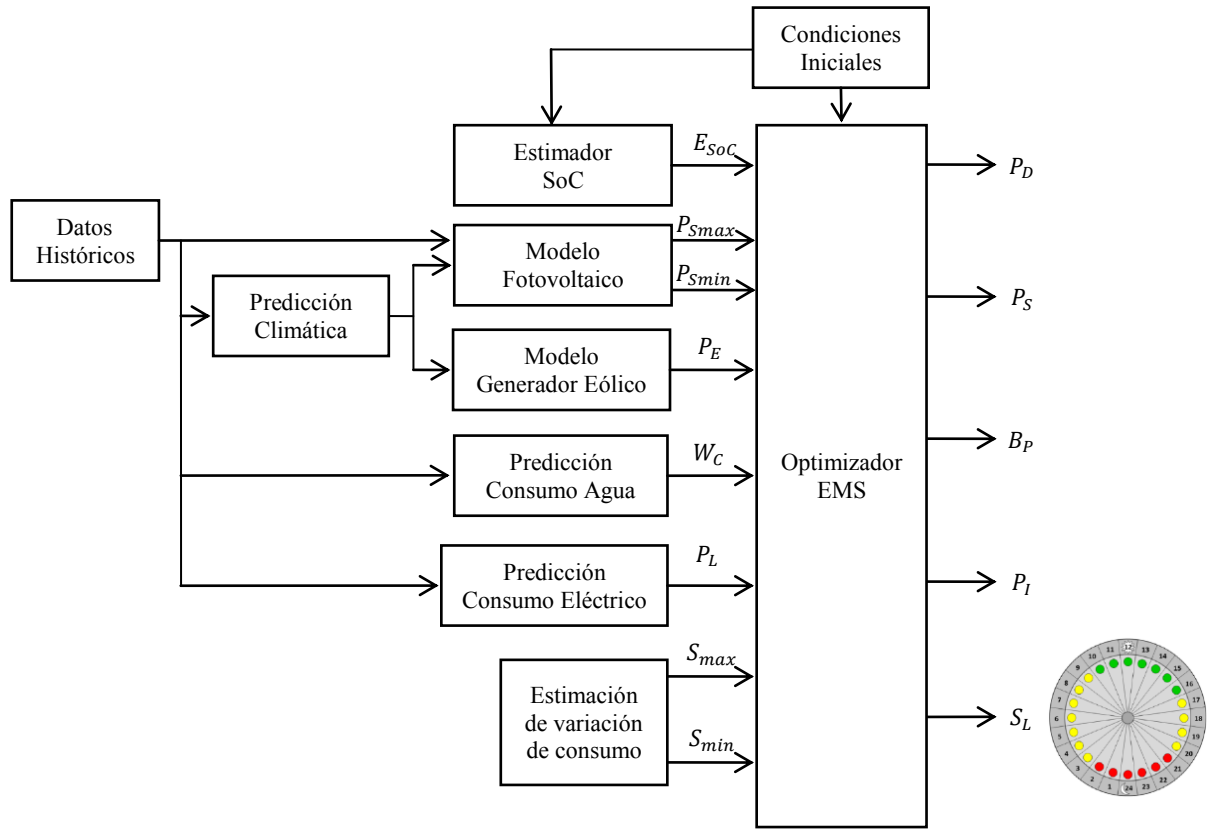


Figura 9. Diagrama del EMS instalado en Huatacondo

Dada las entradas expuestas, cumpliendo la restricción de balance de potencia, en que se debe cumplir con la demanda y suministro de agua, y bajo los modelos de las unidades de generación y almacenamiento de energía, el EMS busca minimizar los costos operacionales para un período T ,

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

en que δ_t es la duración de cada período t , $C(t)$ es el costo de funcionamiento del generador diésel (dado por el costo del combustible), $C_S(t)$ es el costo de encender el generador diésel, C_{US} es el costo (penalización) para la energía no suministrada, $P_{US}(t)$ es la potencia no suministrada, C_{Tf} es el costo (penalización) del agua no suministrada, $V_{Tf}(t)$ es el volumen de agua no suministrada y $C_H(T)$ es el costo de utilizar el banco de baterías [8].

Como se observa de la Figura 9, una de las salidas es el factor de desplazamiento $S_L(k)$, calculada en el proceso de optimización, con la que se obtiene un valor de consumo esperado con gestión de demanda:

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

El factor $S_L(k)$ calculado corresponde a un vector que indica en cuánto se desea que varíe el consumo de los usuarios para el periodo k y está limitado dentro del rango $[S_{min}(k), S_{max}(k)]$, actualmente obtenido de forma empírica, y entregado como entrada al EMS. Se asume que el consumo energético diario se mantiene constante al aplicar estos factores de desplazamiento a un caso base. No se considera una estimación de cómo afecta una determinada secuencia al comportamiento de los usuarios.

Con los factores S_L se definen las señales a enviar por la estrategia de DSM implementada en Huatacondo, que consiste en semáforos indicativos con divisiones horarias, como el de la Figura 10, en que para cada ventana horaria se tiene una luz indicativa con un efecto esperado sobre el consumo del usuario.




Figura 10. Semáforo indicativo para gestión de demanda

Los colores de las luces pueden ser:

- Rojo: disminuir el consumo.
- Amarillo: mantener el consumo.
- Verde: aumentar el consumo.

La secuencia que muestran estos semáforos es enviada de forma inalámbrica a estos indicadores, instalados actualmente en 4 casas de la comunidad.

Para determinar qué color será el que muestre el semáforo teniendo los S_L de salida, se utilizan rangos calculados dados por los valores de S_{min} y S_{max} . Así, el color a indicar se puede definir según la Ecuación (3), en que C_0 y C_1 definen los límites dentro de los que se mostrará uno u otro color:

$$Luz(S_L(k)) = \begin{cases} Verde & \text{si } S_L(k) \geq C_1(k), \\ Amarilla & \text{si } C_0(k) \leq S_L(k) < C_1(k), \\ Roja & \text{si } S_L(k) < C_0(k), \end{cases} \quad (3)$$

donde los límites $C_0(k)$ y $C_1(k)$ se calculan como

$$\begin{aligned} C_0(k) &= S_{min}(k) + \frac{1 - S_{min}(k)}{2}, \\ C_1(k) &= 1 + \frac{S_{max} - 1}{2}. \end{aligned} \quad (4)$$

En palabras simples, si se supera el límite definido como el valor medio entre un factor de desplazamiento nulo y el máximo (o mínimo), se mostrará la luz verde (o roja). Así, si se tiene $S_{min} = 0.95$ y $S_{max} = 1.05$, entonces el límite superior para mostrar el color rojo será $C_0(k) = 0.975$, mientras que el límite inferior para mostrar la luz verde será $C_1(k) = 1.025$.

Esta estrategia aplicada en Huatacondo no considera tarifaciones ni desconexiones automáticas, ya que los usuarios pagan un cargo fijo mensual independiente de su consumo de energía [40]. Así, el principal motivo por el cual los habitantes tendrían una respuesta positiva ante las señales de gestión de demanda presentadas, es el deseo de que la micro-red tenga un buen funcionamiento, lo cual es fomentado con talleres informativos del uso del DSM.

El principal obstáculo para aplicar las estrategias típicas de control de demanda, como son la tarifación por horas, o el incentivo económico, es la posible resistencia de la comunidad para ambas estrategias, factor clave en el funcionamiento de una micro-red: cuando los usuarios no se sienten como una parte activa de la micro-red, es poco probable que se tenga una implementación exitosa.

Es importante tener factores de desplazamiento S_L que sean factibles de obtener mediante la estrategia de DSM implementada, ya que de lo contrario, se tienen consecuencias económicas asociadas, como un alto consumo de diésel. Por ejemplo, se puede entregar un rango $[S_{min}, S_{max}]$ muy alto, superior a la disposición real de la gente de variar su consumo, con lo que puede haber valores de S_L que no se logren con los semáforos instalados.

3.2. Planteamiento del problema

Actualmente, no se considera ni para el proceso de optimización del EMS ni para la estrategia de DSM la respuesta de los usuarios ante las secuencias indicadas por los semáforos y su disposición a cambiar sus patrones de consumo, es decir, no se tiene una cuantificación de qué

significa para los consumidores una luz de color verde, amarillo o rojo. Esto genera que el valor del factor de desplazamiento S_L esté limitado dentro de un rango obtenido empíricamente y no en base a la respuesta de los usuarios, con lo que no se podrá ejercer un control deseado sobre el consumo de la población, con las consiguientes pérdidas económicas asociadas dadas por la diferencia entre la respuesta esperada y la respuesta real de la comunidad.

En este trabajo se busca modelar la respuesta de los usuarios con el fin de limitar las señales de desplazamiento de carga para que se encuentren dentro de un rango razonable de variación de consumo esperado para cada tiempo de muestreo, y que será dado por dicho modelo. Esta respuesta a modelar se define como el consumo con gestión de demanda sobre el consumo de un caso base sin gestión de demanda.

Un modelo completo que estime la respuesta de los consumidores debería considerar la motivación, los hábitos y el acceso a la información que tienen los pobladores como factores a la hora de realizar una estimación, además de otros aspectos, como pueden ser la hora, el clima, la edad o si es un día de semana o fin de semana. Sin embargo, esto podría ser muy complejo y no presentar ventajas significativas frente a modelos más simples. Es por esto que se propone un modelo que estime la respuesta de los consumidores en base a la hora del día y el color del semáforo, dos características fundamentales para el caso de estudio.

La propuesta para resolver el problema presentado se detalla a continuación.

3.3. Metodología propuesta

Para resolver la problemática, se propone estimar la respuesta esperada de los usuarios para cada instante de muestreo y ante las distintas señales del semáforo.

Con el método que se propone, se busca entregar como entradas al optimizador del EMS la variación máxima y mínima de consumo, S_{max} y S_{min} , esperada para cada instante. Dentro de este rango, el optimizador determina un vector de factor de desplazamiento deseado S_L . En la Figura 11 se presenta el diagrama del EMS con la propuesta incluida, presentando las entradas al optimizador dadas por un modelo de respuesta de entrada.

El modelo de respuesta de entrada se encarga de entregar los factores de desplazamiento de potencia máximos y mínimos, teniendo como entradas la hora y color. Para cada hora se tendrán tres respuestas posibles asociadas a cada uno de los colores, el máximo de estas respuestas corresponderá al factor S_{max} , mientras que el mínimo será el factor S_{min} .

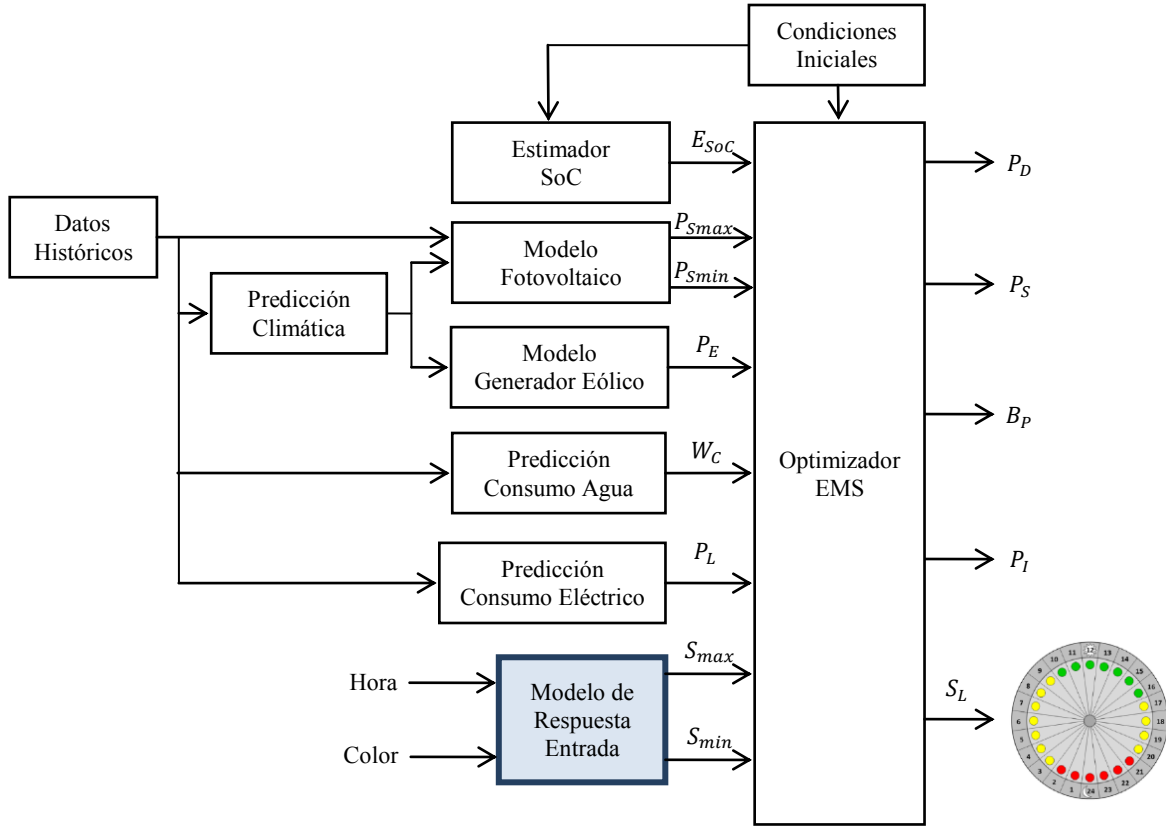


Figura 11. Diagrama de la propuesta

Para la obtención de S_{max} y S_{min} , es necesario desarrollar el modelo difuso tipo Mamdani propuesto en [38], que en base a la hora k y color de luz l como entradas, calcule la variación de potencia $\rho_L(k, l)$ esperada para la comunidad, definida como:

$$\rho_L(k, l) = \frac{P_{S_L}(k, l)}{P_L(k)}, \quad (5)$$

con $P_L(k)$ el consumo base sin gestión de demanda en el instante k , y $P_{S_L}(k, l)$ el consumo con gestión de demanda en el instante k . Utilizando los valores $\rho_L(k, l)$ obtenidos, se pueden derivar los factores S_{max} y S_{min} , que serán dados como entrada al optimizador del EMS.

En el caso de Huatacundo no se tienen datos suficientes con los semáforos instalados como para entrenar un modelo. Para poder ejecutar la metodología propuesta, se considera el desarrollo de un simulador que genere datos de consumo representativos, ya sea por casa o para el pueblo, con gestión de demanda (con el semáforo instalado) y sin gestión de demanda (sin el semáforo instalado). Para la generación de consumos base se propone el uso de cadenas de Markov, mientras que para la respuesta ante los semáforos, se utilizarán redes Bayesianas. Con las demandas generadas se calculan los valores de ρ_L asociados a las entradas. Esto permitirá aplicar distintas secuencias con una alta variabilidad en los colores, por lo que tendrá un amplio set de datos para realizar el entrenamiento.

Obtenidos los datos (en este caso con el simulador, pero que de tener datos reales disponibles, es innecesario para esta propuesta), se entrena el modelo difuso tipo Mamdani utilizando algoritmos genéticos para la determinación de los parámetros de los conjuntos difusos y consecuencias de las reglas. Este modelo puede ser incluido en el proceso de optimización, para así contar con información del comportamiento de los usuarios, ya que la utilización del simulador directamente tiene dos inconvenientes: no entrega valores determinísticos y su tiempo de ejecución puede ralentizar el proceso de optimización. Teniendo como entradas al modelo el color del semáforo y la hora, se busca minimizar la raíz del error cuadrático medio (*Root Mean Squared Error* – RMSE) entre la salida del modelo difuso y el factor ρ_L entregado por el simulador. La expresión para calcular el RMSE se puede apreciar en la Ecuación (6):

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{y}(t) - y(t))^2}, \quad (6)$$

donde $y(t)$ es el valor objetivo, $\hat{y}(t)$ la estimación y n es la cantidad de datos.

Con el modelo tipo Mamdani entrenado, para cada instante de muestreo se calcula la variación de consumo máxima y mínima esperada, obteniendo los vectores de entrada al optimizador del EMS.

Finalmente, esta estrategia se prueba sobre un simulador del EMS [8] para así obtener una cuantificación de los beneficios que traería la inclusión de este bloque de modelación a la micro-red de Huatacondo.

En la Figura 12 se muestra, a rasgos generales, la propuesta a implementar. Como primera etapa se tiene el desarrollo de un simulador, para lo que inicialmente es necesario un pre-procesamiento de los datos de consumo y encuestas. Por una parte se busca tener mediciones completas y a intervalos regulares de consumo; mientras que por otra parte se quiere ordenar datos de encuestas realizadas a la comunidad. Luego se procederá a la obtención de cadenas de Markov, obtenidas a partir de datos medidos, para la generación de consumos base. Sobre estos consumos base se generarán respuestas con redes Bayesianas, entrenadas mediante las encuestas realizadas. Hecho el simulador, se generan datos para el entrenamiento de un modelo difuso tipo Mamdani, mediante la búsqueda de sus parámetros por medio de algoritmos genéticos. Finalmente, y por medio del modelo mencionado, se buscan determinar las entradas al EMS consistentes en S_{min} y S_{max} .

<ul style="list-style-type: none"> ▪ Simulador 	
<ul style="list-style-type: none"> ▫ 	Pre-procesamiento de datos
	Consumo Base
	Generación con cadenas de Markov
	Consumo con Respuesta
	Generación con redes Bayesianas
<ul style="list-style-type: none"> ▪ Modelo 	
<ul style="list-style-type: none"> ▫ 	Modelo difuso tipo Mamdani
	Obtención de conjuntos de las premisas, consecuencias y reglas
<ul style="list-style-type: none"> ▪ Incorporación al EMS con modelo de respuesta del consumidor 	
<ul style="list-style-type: none"> ▫ 	Determinación de entradas al EMS

Figura 12. Propuesta a implementar

Para este trabajo, se considerarán los siguientes supuestos:

- La comunidad está informada del funcionamiento de los semáforos indicativos, y este conocimiento se refleja en encuestas realizadas a la población.
- La elasticidad en el consumo de los usuarios depende tanto de la hora como del color que se indique; así, la respuesta se puede ser modelada en base a esos factores. Considerar todas las variables involucradas para el desarrollo de un modelo requeriría estudios sociológicos y/o psicológicos, no considerados en este trabajo.
- La respuesta de los usuarios se manifiesta a través del distinto uso de los artefactos.
- La decisión de los usuarios se toma en cada momento y no depende de los colores futuros ni pasados indicados por el semáforo.
- Entre las 1 y las 6 a.m., los usuarios no responden ante las señales de gestión, ya que se supone que están durmiendo.

A continuación se explica la primera etapa para llevar a cabo la metodología propuesta, consistente en el desarrollo del simulador de consumo para Huatacondo.

3.4. Simulador de consumo

El simulador a desarrollar generará consumos sin gestión de demanda utilizando cadenas de Markov obtenidas con datos de consumo medidos. Además, las variaciones de consumo generadas por los semáforos se simularán con redes Bayesianas en base a encuestas de consumo realizadas a los usuarios y que tienen como objetivo ser una primera aproximación de la variación de consumo ante las señales del semáforo en las distintas casas sobre la que es aplicada. En base a los datos entregados por este simulador, se puede calcular un factor adimensional de variación de consumo $\rho_L(k)$ según la Ecuación (5) ya presentada.

En la Figura 13, se observa el diagrama con los pasos a seguir para el desarrollo del simulador, dividido en consumos base y generación consumo con respuesta. Para la generación de consumos base, se busca dejar datos procesados para ser utilizados en los pasos siguientes, que buscan determinar la estructura de las cadenas de Markov tanto en el número de estados como en las probabilidades de transición entre ellos, para así poder generar consumos que sean representativos de la comunidad. Para la generación de respuestas de los usuarios ante los semáforos, se busca procesar las encuestas para generar un set de datos, tanto de condiciones iniciales de las redes Bayesianas propuesta como de los valores con los que se entrenará. Estas redes generarán las variaciones de consumo de los usuarios, respecto a un consumo base sin semáforo. Sumando los consumos base y las variaciones de consumo de los usuarios ante el semáforo (estrategia de DSM), se pueden obtener consumos con respuesta ante el DSM.

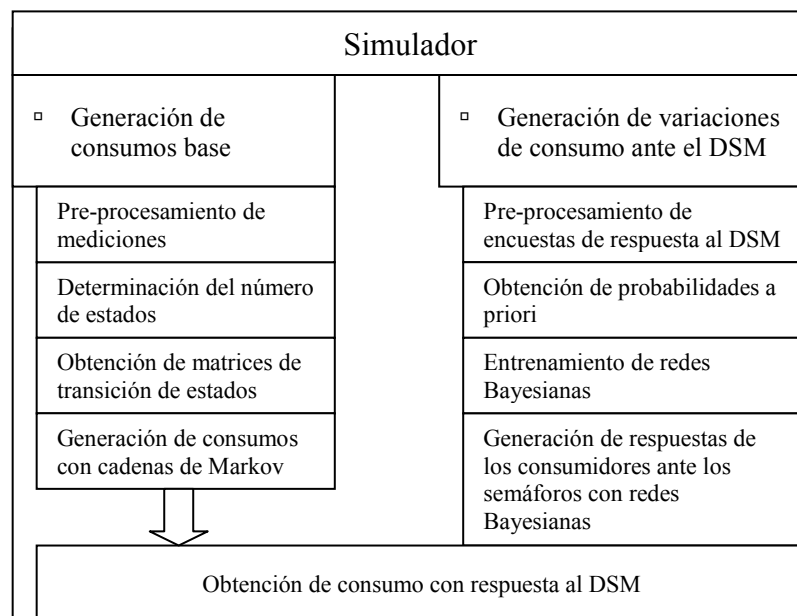


Figura 13. Pasos a seguir para el desarrollo del simulador de consumo

A continuación se detallarán ambas partes del simulador presentado y su interconexión, partiendo por la generación de consumos base representativos de la comunidad.

3.4.1. Generación de consumos base

Para la generación de consumos bases de cada casa, se aprovecha el hecho de que se tienen mediciones de datos reales de Huatacondo obtenidos con contadores de pulsos para 69 días. Es importante recalcar que en esta etapa se debe realizar el estudio en aquellas casas sin semáforos cuando se realizaron las mediciones de consumo, para así no incluir el posible efecto de la gestión de demanda sobre los usuarios. Los contadores son dispositivos que cuentan 800 pulsos por cada kWh de energía consumida, por lo que para obtener un consumo promedio \bar{P} correspondiente a n pulsos medidos en el bloque de 15 minutos entre conteos, se calcula

$$\bar{P}[kW] = \frac{n}{800} [kWh] \cdot \frac{0,25[h]}{1[h]}. \quad (7)$$

Así, para cada tiempo de muestreo se tiene un consumo promedio asociado. En la Figura 14 se observa una curva de consumo ejemplificado para un día de una casa de la comunidad luego de procesar los pulsos contados.




Figura 14. Consumo medido de un día para una casa

Si se considera que cada instante del día tiene características de consumo propias, tanto en los niveles de consumo como en su distribución, es de interés poder generar datos simulados que mantengan estas características y que no sean simples replicaciones de consumos medidos. Esto último con el fin de obtener variabilidad en los datos que permitan ponerse en distintos casos y así generalizar el modelo a obtener posteriormente.

Para esto se propone la utilización de cadenas de Markov discretas en los estados y el tiempo, detalladas en el Anexo B. Las cadenas de Markov consisten en transiciones entre estados

discretos, en que los estados representan lo que se quiere simular (en este caso consumo), en que la transición de un estado i a un estado j tiene una probabilidad asociada p_{ij} , y todas estas probabilidades forman la matriz de transición de estados (MTE). Esto puede ser aplicado para la generación de perfiles aleatorios que mantengan las características de los datos reales medidos, sin ser una mera réplica de estos.

Los supuestos considerados para su aplicación son:

- Una cadena de primer orden es suficiente para la generación de datos de consumo representativos.
- Los datos medidos son representativos de las casas y el pueblo, y las cadenas generarán consumos representativos para el período en que se tomaron esas mediciones.
- Los consumos pueden ser discretizados en estados finitos, sin perder la validez que se le da a la generación de consumos base para este trabajo.
- Las transiciones de estado se dan entre tiempos de muestreo consecutivos.
- Probabilidades iniciales de los estados se mantienen constantes para todos los días a la hora de inicio de la cadena, pero son distintas entre cadenas.

Si se denota n_{ij} como el número de transiciones del estado i al estado j y m la cantidad total de estados, en [41] se demuestra que el estimador de máxima verosimilitud de p_{ij} es

$$\hat{p}_{ij} = \frac{n_{ij}}{\sum_{j=1}^m n_{ij}}. \quad (8)$$

Un punto importante a determinar de las cadenas de Markov es qué representa cada estado. Se propone utilizar el algoritmo *k-means*, explicado en el Anexo B, para realizar un *clustering* sobre los valores de potencia que se usan para determinar una cadena, en que el número de *clusters* corresponden a los estados a utilizar. Se propone este algoritmo en vez de uno difuso porque para contar las transiciones cada dato debe pertenecer sólo a una agrupación. Como resultado se tiene la pertenencia de cada dato a un estado (*cluster*). El centroide de cada *cluster* corresponde al valor de potencia que tomarán los datos generados por medio de las cadenas de Markov.

Uno de los parámetros a definir es el número de estados que tendrá la cadena. En [42] se deriva un método (detallado en el Anexo B) para determinar una cota superior del número de estados que son válidos para que la cadena represente los datos disponibles, bajo ciertos parámetros de diseño p^* y t . Se busca la máxima probabilidad p^* que se puede aceptar de que el estimador de máxima verosimilitud de p_{ij} varíe en t respecto a su valor real. Sea $n_i = \sum_{j=1}^m n_{ij}$ el número de transiciones que se dan a partir del estado i a cualquiera de los $j = 1 \dots m$ estados, entonces la cota superior se define como:

$$c(n_i) = \min \left\{ 1, 2e^{-2n_it^2}, \frac{1}{4n_it^2} \right\}. \quad (9)$$

Mediante un proceso iterativo se obtiene que el número máximo de estados m^* es aquel que hace cumplir $c(n_i) \leq p^*$ para todos los estados i .

Cuando la cantidad de datos es reducida, y dependiendo de los parámetros de diseño p^* y t , es posible que el procedimiento anterior arroje $m^* = 1$ como la máxima cantidad de estados que cumplen los criterios. En estos casos es conveniente agrupar datos que tengan características similares, es decir, que se encuentren en un rango de valores similares, con el fin de tener una mayor cantidad de datos para la caracterización adecuada de los parámetros de la cadena de Markov. Para efectos de esta memoria, se agrupan datos que tengan tiempos de muestreo consecutivos, con el fin de contar transiciones de estado entre muestras consecutivas.

Para definir estos grupos, primero se calculan características de la potencia consumida para cada tiempo de muestreo, y que reflejen entre qué valores se encuentra esta potencia. Estas características son: *mínimo*, *máximo* y *media*. Con estas características para cada tiempo, se determinará qué rangos horarios tienen características similares entre sí, minimizando las diferencias *intragrupos*.

Dado el número de grupos s deseados, determinados de forma heurística, se busca minimizar la distancia entre las características de los datos y la media de estas características pertenecientes a un mismo grupo. En las Ecuaciones (10) y (11) se formaliza la propuesta. Sea S_j el grupo de datos j , con $j = 1 \dots s$, se cumple que $x \in S_j \Leftrightarrow x \in [l_j, l_{j+1}[$, en que los l_j son los límites de tiempos de muestreo, que van de 1 a 96. En el caso extremo para el conjunto S_s , se tiene que $x \in S_s \Leftrightarrow x \in [l_s, 96] \cup [1, l_1[$, ya que llegado a $k = 96$ (el final del día), se vuelve a $k = 1$ (el inicio del día siguiente). Sea N_j la cardinalidad del conjunto S_j y x el vector de características, entonces:

$$\bar{\mu}_j = \frac{1}{N_j} \sum_{x \in S_j} x, \quad (10)$$

$$\min_{l_1, \dots, l_s} J = \sum_{j=1}^s \sum_{x \in S_j} \|x - \bar{\mu}_j\|^2. \quad (11)$$

La minimización del funcional J se realizará con algoritmos genéticos, explicados en el Anexo B, con el objetivo de evitar mínimos locales. Los cromosomas de los individuos estarán conformados por los límites de los conjuntos S_j .

En un caso general, si se consideran s grupos por casa, cada uno con m_g estados ($g = 1 \dots s$), se tiene que para cada casa c se tendrán matrices de transición de estados con los estimadores de máxima verosimilitud de la forma:

$$P_g^c = \begin{bmatrix} \hat{p}_{11} & \hat{p}_{12} & \cdots & \hat{p}_{1m_g} \\ \hat{p}_{21} & \hat{p}_{22} & \cdots & \hat{p}_{2m_g} \\ \vdots & & \ddots & \\ \hat{p}_{m_g1} & \hat{p}_{m_g2} & \cdots & \hat{p}_{m_gm_g} \end{bmatrix}. \quad (12)$$

Para determinar las probabilidades iniciales de los estados de la cadena de Markov, para cada estado se calcula una probabilidad proporcional al número de datos que pertenecen a dicho estado en el tiempo de muestreo inicial en que la cadena es válida. Sea p_i la probabilidad de que el estado inicial de la cadena sea el estado i , m el número de estados y n_i el número de datos que pertenecen al estado i para dicho tiempo de muestreo en que la cadena (correspondientes a los l_j , con $j = 1 \dots s$), entonces se tiene que:

$$p_i = \frac{n_i}{\sum_{j=1}^m n_{ij}}. \quad (13)$$

Teniendo la cadena con sus estados y probabilidades de transición asociadas, se debe determinar cómo se harán las realizaciones para la generación de datos. Para esto, se sigue el siguiente procedimiento:

- Dividir el intervalo real $[0,1]$ en m divisiones, cada una de largo igual a la probabilidad \hat{p}_{ij} de la MTE.
- Se hace una realización de una variable aleatoria con distribución uniforme en el intervalo cerrado $[0,1]$.
- Revisar a cuál de las m divisiones pertenece el valor obtenido, y ese será el estado al cual se hará la transición.

Esto se ejemplifica en la Figura 15, en que aprecia la división del intervalo y la realización de la variable aleatoria con distribución uniforme, que en ese caso cayó en el estado e_2 .




Figura 15. Realización de transiciones

En la Figura 16 se ejemplifica la propuesta de cadena de Markov, en que se tienen s cadenas de Markov, cada una válida dentro de un rango de tiempo, y que generan datos de consumo base de potencia. Al ser cada cadena independiente de las otras, los datos generados por las s cadenas se concatenan para obtener la serie temporal de consumos base.

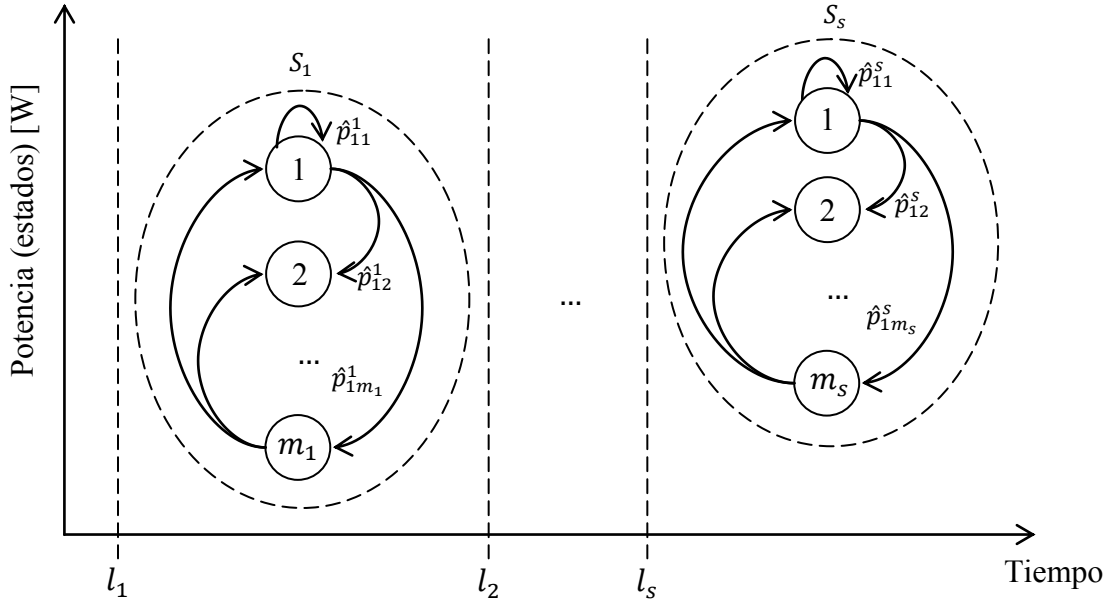


Figura 16. Esquema para la generación de datos con cadenas de Markov

Como una medida de verificación de los modelos generados, se propone comparar el RMSE y el error porcentual absoluto medio (*Mean Absolute Percentage Error* – MAPE) de las medias por tiempo de muestreo de los consumos generados y reales, y la diferencia en la media de la energía consumida entre dichos consumos. El cálculo del MAPE se puede apreciar en la Ecuación (14):

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{\hat{y}(t) - y(t)}{y(t)} \right|, \quad (14)$$

donde $y(t)$ es el valor objetivo, $\hat{y}(t)$ es la estimación y n es el número de datos.

Con el proceso descrito en esta sección, se podrán obtener cadenas de Markov que permitan la generación de consumos base representativos por casa, sobre los cuales se podrá determinar la respuesta que tendrán los usuarios ante el DSM, proceso que se describirá en la siguiente sección.

3.4.2. Generación de consumos con respuesta del consumidor al DSM

Es de importancia tener una estimación de cómo los pobladores modificarán su consumo ante las señales de gestión de demanda entregadas por el semáforo indicativo, con el fin de calcular los valores de factor de respuesta ρ_L .

Teniendo en cuenta este objetivo, se aplican 41 encuestas de utilización de artefactos a 14 casas de la comunidad, adjuntas en el Anexo A, por bloques horarios entre las 7 y las 24 horas. Las secuencias a presentar consisten en un semáforo típico (día soleado o nublado) y uno no típico (que generalmente no se da en esa zona), además de un caso base sin semáforo sobre el cual se analizarán las variaciones de consumo.

Los usuarios deben indicar en qué horarios utilizan los artefactos en sus casas y cómo conectarían o desconectarían algunos de ellos, dependiendo de la secuencia que entregue el semáforo. Para cada uno de los artefactos indicados en la encuesta se tiene una potencia, una utilización y un ciclo de uso típicos, que representan:

- **Potencia nominal (P_{nom}):** Potencia máxima que consume el artefacto.
- **Fracción de utilización por hora (Ut):** Tiempo en base horaria que es utilizado típicamente un artefacto, en que un valor igual a 1 indica que se usa la hora completa.
- **Ciclo de uso ($Ciclo_{uso}$):** Factor que escala la potencia nominal del artefacto, ya que no trabaja a máxima potencia durante todo el tiempo en que es usado.

Así, la potencia promedio consumida por artefacto para cada bloque horario es la obtenida al aplicar la Ecuación (15).

$$E = P_{nom} \cdot Ut \cdot Ciclo_{uso} . \quad (15)$$

Los valores para cada artefacto en cuestión, se pueden apreciar en la Tabla 2.

Tabla 2. Uso típico de los artefactos encuestados [41]

Artefacto	Potencia Nominal [W]	Fracción de utilización por hora	Ciclo de uso [%]
Refrigerador	195	1.00	42
Horno Eléctrico	1300	1.00	100
Hervidor	900	0.08	100
TV	100	1.00	100
Plancha	1000	1.00	60
Lavadora	520	1.00	35
Radio	60	1.00	100
Microondas	800	0.50	80
Ampolleta	23	1.00	100
Plancha Cabello	500	0.15	100
Congelador	180	1.00	50
Computador	300	1.00	100
Utensilios de Cocina	500	0.50	80

En base a la Tabla 2, se puede tener la potencia consumida en el caso base sin semáforo de una encuesta, y contrastar este consumo con una encuesta con un semáforo asociado; así, se tiene la variación para la hora y el color encuestado, para cada uno de los artefactos. El conjunto de las respuestas a la encuesta dadas por los usuarios conforman la base de datos con los que se trabajará en el simulador.

Se debe considerar que las variaciones de consumo ante las distintas secuencias no son determinísticas, por lo que tienen un grado de incertidumbre que debe ser incluido. Para incluir esta incertidumbre y extender las respuestas de los usuarios para cualquier hora y color de entrada, se utilizarán redes Bayesianas, detalladas en el Anexo B. Estas redes se representan como un grafo dirigido y acíclico conformado por nodos, en que cada nodo representa una variable aleatoria y tiene asociada una tabla de probabilidades condicionales (*Conditional Probability Table – CPT*), que indican las probabilidades de tomar distintos valores dados los valores de sus padres [44].

Para esta aplicación, cada artefacto de la encuesta contará con su propia red Bayesiana, ya que se supone que la disposición a utilizar o dejar de utilizar es distinta para cada uno. Se utiliza un razonamiento en que se tienen las causas (padres) como evidencia y se busca las consecuencia (hijos) más probable [45].

Con el supuesto previo de los factores que alteran la decisión de los usuarios, se establece la topología de la Figura 17 para la red Bayesiana de un artefacto. En este caso, los nodos K y L (representando la hora y el color de la luz, respectivamente) son multinomiales: en el primer caso puede tomar 18 valores (entre las 7 y 24 horas), mientras que en el segundo puede tomar 3 valores (verde, amarillo y rojo). Por su parte, los nodos E y S son binarios, indicando el estado base del artefacto (encendido o apagado), y si el estado o no varía, respectivamente.




Figura 17. Grafo de la red Bayesiana propuesta para las encuestas

Como se puede observar en la Figura 17, los nodos padres son K y L . Se establecen dependencias de la hora para el estado base de cada artefacto (nodo E) y dependencias de la hora, color y estado base, para determinar si existe variación o no respecto a cómo se encontraba el artefacto inicialmente (nodo S), ya que una carga puede ser apagada (o encendida) sólo si estaba encendida (o apagada) inicialmente. Las evidencias son la hora y el color del semáforo, mientras que las interrogantes son el estado del artefacto y si éste varía.

Las CPT para el estado y la variación se muestran en la Tabla 3 y Tabla 4, en que el color verde se representa con un 1, el amarillo con un 2 y el rojo con un 3.

Tabla 3. CPT para la probabilidad del estado

Hora	$P_{art}(on K, L, E)$	$P_{art}(off K, L, E)$
7	p_1	$1 - p_1$
8	p_2	$1 - p_2$
\vdots	\vdots	\vdots
24	p_{24}	$1 - p_{24}$

Tabla 4. CPT para la probabilidad de variación de estado

Hora	Color	Estado	$P_{art}(var K, L, E)$	$P_{art}(\bar{var} K, L, E)$
7	1	<i>on</i>	p_1	$1 - p_1$
7	2	<i>on</i>	p_2	$1 - p_2$
\vdots	\vdots	\vdots	\vdots	\vdots
24	3	<i>off</i>	p_{108}	$1 - p_{108}$

Preguntar todos los casos posibles en las encuestas sería poco práctico y desgastador tanto para el encuestado como para el encuestador, por lo que hay combinaciones de hora y color que no se dan en la base de datos. Esto genera que la red Bayesiana sea de estructura conocida, pero con datos incompletos.

Para el entrenamiento de una red Bayesiana con datos incompletos se utiliza el algoritmo *Expectation Maximation* (EM), propuesto en [46] y explicado en el Anexo B. Este es un algoritmo iterativo, que converge a un *máximo local* de la función de verosimilitud. Es por esto que es necesario dar una conjetura inicial (θ^0) de los parámetros adecuada y que refleje cómo se espera que la población reaccione en distintas situaciones, esperando que el máximo al que converja sea el que mejor explique (y extienda) los resultados de la encuesta para cada una de las casas.

Estas probabilidades *a priori* por casa son establecidas utilizando las respuestas de todas las encuestas realizadas en el pueblo, siempre que la casa en cuestión posea el artefacto. Se toma como supuesto que la gente de la misma comunidad tiene reacciones relativamente similares. En el caso de combinaciones de variables hora y color de las que no se tenga registro, se calculará la probabilidad *a priori* de variar el estado del artefacto como sólo dependiente del color del semáforo.

Obtenidos los parámetros que maximizan la verosimilitud, se tienen las tablas de probabilidades condicionales que definen la red Bayesiana. Como las evidencias de la red son la hora y el color del semáforo, al entregar estos datos se obtienen las probabilidades $P_{art}(on|K)$ y $P_{art}(var|K, L, E)$. En base a estas probabilidades se generan realizaciones de la red, con el procedimiento descrito en la Sección 3.4.1, obteniendo el estado del artefacto y si existe variación de ese estado. Solo en los casos en que exista variación se habrá generado respuesta en los usuarios, ya sea aumentando o disminuyendo el consumo. En la Tabla 5 se muestran las combinaciones posibles para el artefacto y cuál es su efecto sobre la variación de potencia.

Tabla 5. Salidas posibles de la red Bayesiana

Estado	Variación	ΔP
<i>on</i>	Sí	-
<i>on</i>	No	0
<i>off</i>	Sí	+
<i>off</i>	No	0

Al realizar este procedimiento, se pueden dar casos en que varios artefactos respondan a la vez a la luz, reacción que potencialmente puede hacer que la respuesta escape de rangos razonables, como aumentar el consumo de forma exagerada o llegar a un consumo nulo. Para reducir el impacto de estas múltiples reacciones, y apoyado por datos de consumo base y las encuestas, por casa se sugiere:

- Comparar el consumo total P_{LB}^c de todos los artefactos que la realización dio como encendidos y comparar con el consumo P_L^c generado por la cadena de Markov. Aleatoriamente, y con una distribución uniforme, apagar iterativamente artefactos de tal forma que se cumpla que $P_{LB}^c \leq P_L^c$.
- Estudiar las encuestas para determinar cuántos electrodomésticos responden como máximo a la vez ante las señales de gestión de demanda. Obtenida esta cantidad n , se procede a seleccionar, aleatoriamente y en base a una distribución uniforme, n cargas de las que tuvieron un cambio respecto a su estado base, si es que hubo cargas que respondieron.

Ejecutando el algoritmo descrito para todos los tiempos de muestreo y artefactos, se tiene cuáles se encienden y apagan, cálculo que es realizado cada 15 minutos, bajo el supuesto de que la toma de decisiones se realiza cada 15 minutos, por lo que la acción al inicio del bloque horario no necesariamente se mantendrá para toda la hora. Multiplicando estas variaciones por las potencias típicas de los artefactos de la Tabla 2 y sumándolas, se obtiene una variación de consumo $\Delta P_L^c(k, l)$ para cada tiempo k y color l , por casa c .

Los supuestos considerados para la utilización de redes Bayesianas en esta aplicación son:

- Las encuestas reflejan fielmente los comportamientos y respuestas que tendrían los usuarios ante las señales indicativas.
- Cada artefacto de cada casa tiene un distinto modo de utilización y propensión a ser encendido o apagado.
- Las respuestas de los usuarios para el color pueden ser utilizadas como una buena estimación inicial cuando se tienen datos faltantes de combinaciones de hora y color.
- Las respuestas de los consumidores no varían entre los días de semana y fines de semana.
- Los consumidores pueden cambiar sus decisiones dentro de un mismo bloque horario, siguiendo las mismas probabilidades.

En la siguiente sección se describirá cómo las cadenas de Markov y las redes Bayesianas se complementan para dar forma al simulador de consumo propuesto.

3.4.3. Estructura del simulador

Para la obtención del simulador, se unen los desarrollos la Sección 3.4.1 para la generación de consumos base, y la Sección 3.4.2 para la generación de respuesta ante los semáforos.

En la Figura 18 se puede observar la estructura final del simulador de consumo, en que el consumo base sin gestión de demanda está dado por las realizaciones de las cadenas de Markov (que utilizan como base de datos las matrices de transición de estado P_g^c , con g el número de cadenas por casa c), obteniendo el consumo $P_L^c(k)$ para cada instante k y para cada casa c . Sumando todos los consumos generados, se obtiene el consumo total de la comunidad $P_L(k) = \sum_c P_L^c(k)$. De la misma forma, se suman todas las variaciones de consumo obtenidas con redes Bayesianas (cuyas CPT se representan en la base de datos por R_{art}^c , para cada artículo de cada casa c), para tener la variación de consumo total de la comunidad $\Delta P_L(k, l) = \sum_c \Delta P_L^c(k, l)$, en que l indica la luz del semáforo en el tiempo k .

Sumando el consumo base con su variación de consumo asociada, se tiene el consumo de la comunidad que resulta de aplicar la estrategia de gestión de demanda:

$$P_{S_L}(k, l) = P_L(k) + \Delta P_L(k, l) . \quad (16)$$

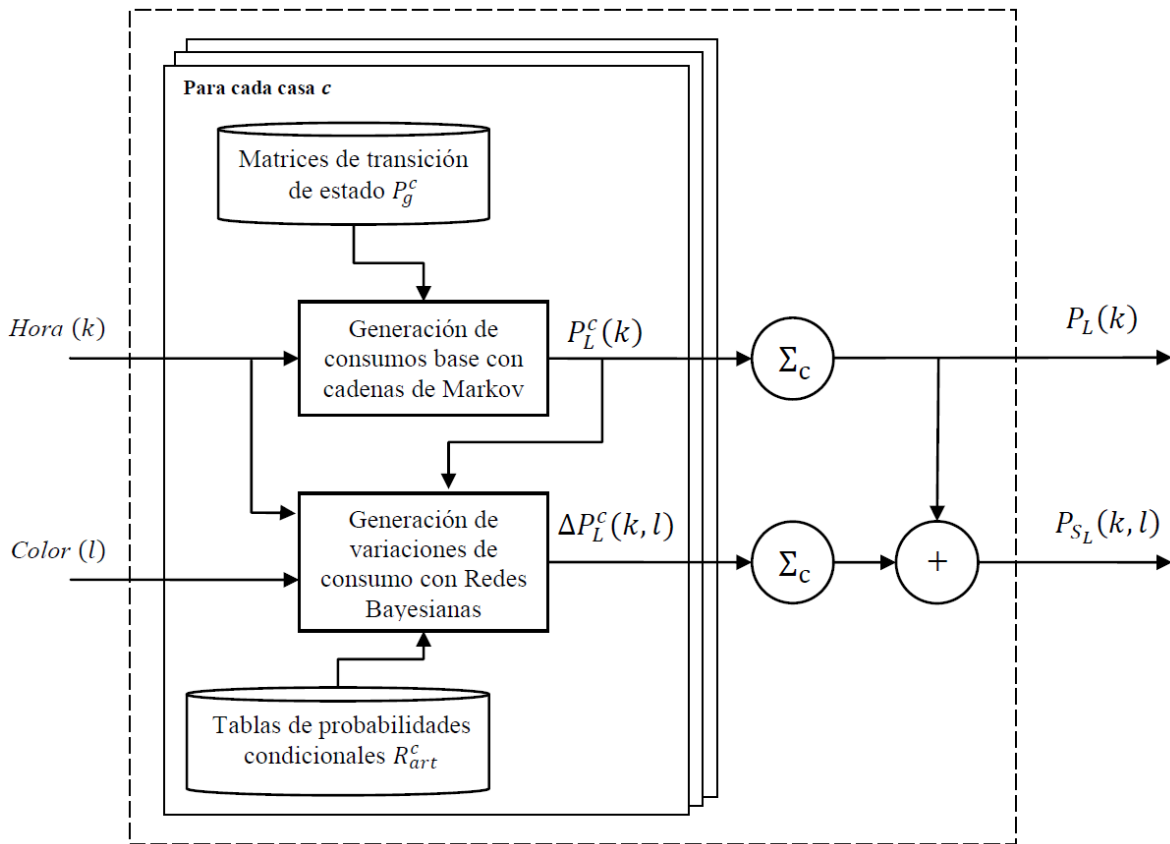


Figura 18. Estructura del simulador

Con las salidas del simulador, se puede calcular el factor de respuesta asociado a las entradas, como se muestra a continuación.

3.4.4. Cálculo del factor de variación de consumo

Obtenidos los consumos con y sin gestión de demanda para la comunidad con el simulador, se dimensiona en cuánto varió el consumo con gestión respecto al consumo base. Para esto, se calcula un factor de respuesta como:

$$\rho_L(k, l) = \frac{P_{S_L}(k, l)}{P_L(k)}. \quad (17)$$

Cada factor calculado tendrá asociado la hora en el instante k y el color de la luz l del semáforo que generó esta respuesta.

La selección de un factor multiplicativo viene dada porque a partir de este factor $\rho_L(k, l)$ se pueden obtener los factores de desplazamiento $S_{max}(k)$ y $S_{min}(k)$ de entrada al optimizador del EMS, siendo estos asignados al máximo y mínimo valor de $\rho_L(k, \cdot)$ que se obtenga con el modelo tipo Mamdani para los distintos colores de entrada en un tiempo k dado; es decir, las mayores expectativas de variar el consumo para cada tiempo.

3.4.5. Generación de semáforos

La entrada al simulador consiste en las secuencias de colores que son mostradas por los semáforos indicativos de gestión de demanda. Se busca que esta entrada sea lo más variada posible con el fin de obtener un modelo que entregue una estimación adecuada para todos los posibles casos de secuencias a los que se enfrente.

Como no existen limitaciones en las señales que se pueden mostrar en distintas horas, se generan secuencias aleatorias de semáforos. De esta forma, se propone generar las secuencias con una cadena de Markov con 3 estados correspondientes al color de la luz a indicar.

El usar cadenas de Markov proporciona flexibilidad en la generación de secuencias, ya que sus probabilidades de transición se pueden definir como equiprobables o por alguna heurística si se desean imponer ciertas restricciones en las transiciones entre colores.

Como salida, se tendrá un vector de 24 elementos, uno para cada hora, que serán el semáforo ante el cual se querrá determinar la respuesta de los usuarios.

3.4.6. Generación de otros consumos

Los consumos base se generarán individualmente sólo para aquellas casas que tengan registros. Para el resto de la comunidad, se utilizará una cadena de Markov general obtenida en base al consumo del pueblo descontando el consumo de las casas con mediciones. Esta cadena representará al conjunto de las casas no consideradas individualmente.

En el caso de la respuesta a la gestión de demanda, para las casas en que se tenga respuesta por medio de las encuestas se utilizará la red Bayesiana obtenida por casa. En el caso del resto de

las casas, se usará una red obtenida con el total de las encuestas realizadas en la comunidad, que constituirá una lógica promedio de respuesta.

Con el desarrollo del simulador y la generación aleatoria de semáforos, se pueden generar perfiles de consumo con y sin gestión de demanda para la totalidad del pueblo, a partir de los cuales se obtienen los factores de respuesta asociados. A continuación, se detalla el modelo de la respuesta de los usuarios, entrenado con los datos generados.

3.5. Modelo de respuesta del consumidor

Desarrollado el simulador y generando respuestas ante distintas secuencias de semáforos, se tendrá un conjunto de datos de entrada y salida. Este set de datos es para la totalidad de la comunidad y las entradas consisten en la hora del día y el color que se muestra, mientras que la salida corresponde al factor de respuesta $\rho_L(k, l)$ asociado a las entradas. Es de interés generar un modelo que estime esta respuesta para ser incluido en el EMS y así considerar la respuesta de los usuarios ante el DSM.

Como se mencionó anteriormente, el simulador se diseñó por la falta de datos con gestión de demanda. De haber tendido suficientes datos, se podría haber realizado el entrenamiento del modelo con datos medidos de consumo sin utilizar el simulador.

3.5.1. Modelo difuso tipo Mamdani

El modelo propuesto para la labor anteriormente descrita es un modelo difuso tipo Mamdani, descrito por F. Ávila en [38] y ejemplificado en la Figura 19, en que se tienen los conjuntos de las premisas: Luz del semáforo (verde, amarilla y roja) y la hora del día (mañana, tarde y noche). También se muestran los conjuntos de la consecuencia, correspondientes al factor de respuesta ρ_L (bajo, medio y alto).

Este número de conjuntos para la hora y el factor de corrección no son definitivos y pueden variar, dependiendo del modelo que entregue los mejores resultados. Por su parte, la entrada *color* tiene fijo el número y forma de los conjuntos, ya que no hay más posibilidades a mostrar.

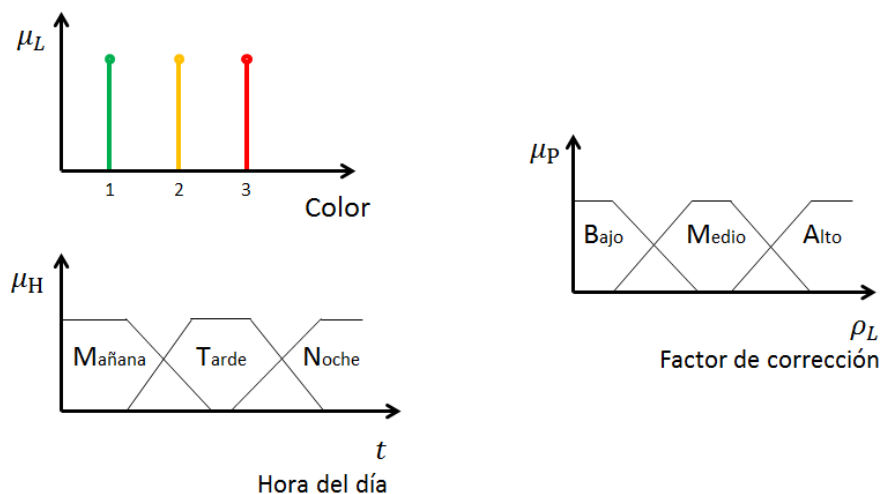


Figura 19. Conjuntos difuso para la estimación de variación de consumo [38]

La modelación tipo Mamdani es de interés para esta aplicación dado que utiliza las reglas lingüísticas de la lógica difusa, más cercanas a la lógica humana. En este caso particular, las reglas son de la forma:

$$R_i: \text{ "Si hora es } H_j \text{ y color es } L_k, \text{ entonces } \rho_L \text{ es } P_l \text{ "}$$

En que H_j es un concepto lingüístico, representado por un conjunto difuso, como “mañana” o “noche”, L_k representa un color, como “verde” o “rojo”, y P_l es la consecuencia del cumplimiento de la regla, que puede representar “disminuye” o “aumenta” [47]. Más información de la modelación difusa tipo Mamdani, se puede encontrar en el Anexo B.

De esta forma se espera modelar el razonamiento que puede tener la comunidad en su conjunto. Además, este tipo de modelos genera salidas determinísticas dadas las entradas, una vez que ha sido entrenado con los datos simulados.

Como factores a considerar en la estructura de un modelo tipo Mamdani, se encuentran el número de conjuntos de las premisas y consecuencias, la forma de los conjuntos difusos y la *desfusificación*, que transforma las activaciones de las reglas a un valor único de salida. Estos factores deben seleccionarse en base al desempeño que tenga el modelo frente a otros con distintas estructuras.

Para determinar el grado de cumplimiento de cada regla, se tienen dos posibilidades para el procesamiento de los antecedentes: usar el mínimo o el producto entre los grados de pertenencia de las premisas a sus conjuntos. Entonces se tiene que para un dato de hora y color (h, c) :

$$R_i(h, c) = \min \{ \mu_{H_j}(h), \mu_{L_k}(c) \}, \quad (18)$$

$$R_i(h, c) = \text{prod} \{ \mu_{H_j}(h), \mu_{L_k}(c) \}, \quad (19)$$

en que $\mu_{L_k}(c)$ es el grado de pertenencia del color c al conjunto L_k , $\mu_{H_j}(h)$ el grado de pertenencia de la hora h al conjunto H_j y $R_i(h, c)$ el grado de cumplimiento de la regla R_i . Como en este caso particular el grado de pertenencia a un determinado color será 1 o 0 (binario), se tiene que ambos métodos son equivalentes. Esto se puede mostrar analizando los casos en que $\mu_{L_k}(c)$ toma ambos valores: si $\mu_{L_k}(c) = 0$ se tiene que $\min \{ \mu_{H_j}(h), 0 \} = \text{prod} \{ \mu_{H_j}(h), 0 \} = 0$; en el caso en que $\mu_{L_k}(c) = 1$, entonces $\min \{ \mu_{H_j}(h), 1 \} = \text{prod} \{ \mu_{H_j}(h), 1 \} = \mu_{H_j}(h)$. Así, para este caso particular, es indiferente cuál de los dos métodos utilizar. En este caso se utiliza el mínimo, por su menor costo computacional.

Para la obtención del conjunto de la consecuencia, se usa la composición *max-min*, en que $R_i(h, c)$ es el grado de cumplimiento de la regla i dadas las entradas y μ_{P_l} la función de pertenencia del conjunto de salida P_l asociado a la regla R_i . Así, se tiene que el conjunto $P'(h, c)$ final de la consecuencia queda definido por su grado de pertenencia $\mu_{P'}$:

$$\mu_{P'}(\rho_L) = \max_i [\min \{ R_i(h, c), \mu_{P_l}(\rho_L) \}], \quad \forall \rho_L. \quad (20)$$

Para la defusificación, se opta por el centro de gravedad del conjunto $P'(h, c)$.

Dada cierta estructura, se deben encontrar los parámetros que minimicen el RMSE, entre la salida del modelo y la salida objetivo: para esto se cuenta con el conjunto de entrenamiento, que es sobre el cual se minimiza el RMSE, y el conjunto de test, cuyo RMSE indica hasta cuándo se debe entrenar el modelo. Finalmente, para comparar entre distintos modelos, se utiliza el conjunto de validación y se evalúa el RMSE entre ellos.

Para el entrenamiento del modelo se utilizan algoritmos genéticos que buscan minimizar el RMSE, tomando como variable de optimización los parámetros de los conjuntos difusos de las premisas y de las consecuencias de las reglas.

Como en el caso de este problema no existen limitantes para los colores del semáforo que pueden ser mostrados a cada hora, se pueden dar todas las combinaciones posibles de reglas. De esta forma, el número de reglas totales para el modelo difuso está dado por la multiplicación de la cantidad de conjuntos difusos de cada una de las entradas al modelo. Para el caso de estudio, el número de reglas es

$$n_r = 3 \cdot cjt_h, \quad (21)$$

donde cjt_h es el número de conjuntos difusos para la hora, y está multiplicado por 3 porque ese es el número de conjuntos para el color. Así, se tendrán n_r variables discretas a considerar para la obtención de las consecuencias. En la Ecuación (22) se muestra un ejemplo de las consecuencias de las reglas para dos entradas de tres conjuntos difusos cada una, totalizando nueve reglas, y sus consecuencias representadas por $X_{h,l}$, que puede tener un significado del tipo *bajo*, *medio* o *alto*.

$$\begin{aligned} R_1: & \text{Si hora es Mañana y color es Verde, entonces } \rho_L \text{ es } X_{M,V}, \\ & \dots \\ R_9: & \text{Si hora es Noche y color es Rojo, entonces } \rho_L \text{ es } X_{N,R}. \end{aligned} \quad (22)$$

En la Figura 20 se muestran los pasos a seguir para la obtención del modelo de respuesta de los consumidores, en que los datos para el entrenamiento, test y validación son los generados con el simulador descrito en la Sección 3.4. Para el entrenamiento del modelo, es necesaria la obtención de un set de entradas y salidas. Dadas las entradas, consistentes en la hora y el color de la luz del semáforo, se variarán parámetros del modelo para minimizar el error entre la salida del modelo respecto a la salida objetivo, consistente en el factor de respuesta ρ_L . Una vez que el modelo está entrenado, se puede obtener una estimación de la respuesta de la comunidad ante un color mostrado a una hora específica.

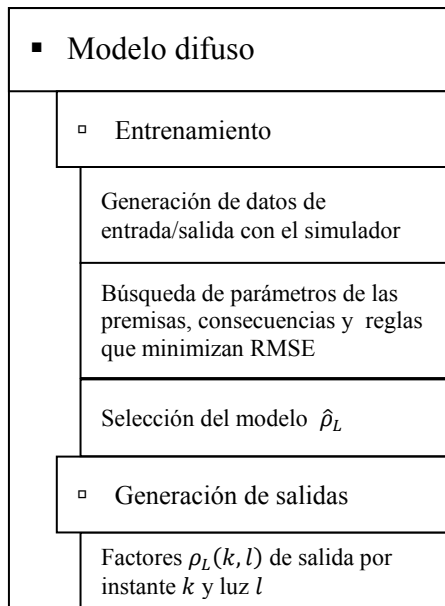


Figura 20. Pasos a seguir para la obtención del modelo

Teniendo el modelo difuso de respuesta de los consumidores, es de interés incluirlo al EMS, metodología que se verá en el siguiente punto.

3.6. EMS con modelo de respuesta del consumidor

El modelo tipo Mamdani entrenado, denotado como $\hat{\rho}(k, l)$, se utiliza para determinar las máximas y mínimas variaciones de consumo por tiempo de muestreo. En la Figura 21 se indica el procedimiento general de inclusión al EMS, en que en base al modelo difuso se buscan los factores de desplazamiento máximo y mínimo para cada tiempo de muestreo k , que consistirán en las entradas al EMS que limitan el rango dentro del que se puede esperar una respuesta de los usuarios.

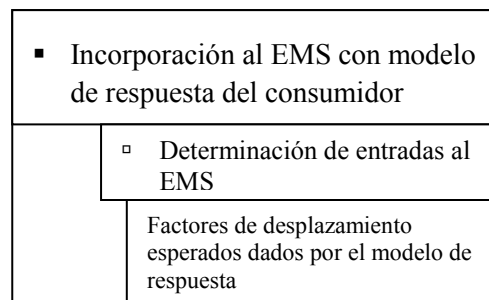


Figura 21. Pasos a seguir para la incorporación al EMS

Se propone dar como entrada al modelo los pares $[k, 1]$, $[k, 2]$ y $[k, 3]$ en cada instante k , es decir, probar con los tres colores posibles del semáforo, para un mismo tiempo. Así, se tendrán 288 pares de entrada al modelo y los factores S_{min} y S_{max} se calculan como:

$$S_{min}(k) = \min_{l=1,2,3} \hat{p}(k, l),$$

$$S_{max}(k) = \max_{l=1,2,3} \hat{p}(k, l).$$
(23)

Para aquellos horarios en que no haya respuesta ante el DSM, entre las 00:55 y 06:55, se tiene que $S_{min}(k) = S_{max}(k) = 1$.

Al realizar el proceso de optimización del EMS con estos factores de desplazamiento máximos y mínimos de entrada, el EMS entrega como salida un vector S_L de factores de desplazamiento de consumo deseados, que son los que optimizan el funcionamiento de la micro-red, dadas las restricciones energéticas.

3.7. Discusión

Se busca incluir al EMS un modelo de respuesta de los usuarios ante el DSM. Dado que no se tienen suficientes datos reales, se propone el desarrollo de un simulador de consumo, que permita realizar pruebas y aplicar señales de gestión variadas sin afectar a los consumidores para tener un dimensionamiento del impacto de estas estrategias.

Este simulador utiliza mediciones reales de la comunidad y encuestas de consumo realizadas. Para la generación de consumos base se utilizan cadenas de Markov, que generan datos representativos si se sigue un procedimiento para la selección de estados. Para la respuesta de los usuarios ante la estrategia de gestión de demanda se usan redes Bayesianas, que tienen como característica el generar probabilidades condicionales. Aún en casos en que no se tienen datos completos, se puede realizar este entrenamiento, como es este caso con las encuestas de consumo.

La metodología propuesta para incorporar el modelo de respuesta al EMS tiene la ventaja de que no aumenta los tiempos de minimización de la función objetivo ni los tiempos de cálculo de forma significativa, ya que el entrenamiento del modelo se realiza fuera de línea y además no se incluye un modelo dentro del optimizador, lo que aumentaría el tiempo de cómputo.

Aunque esta metodología será aplicada para datos obtenidos en Huatacondo, permite ser utilizada en otras comunidades, en que se tengan datos similares y una estrategia de gestión de demanda similar.

4. Implementación

Se expondrá la implementación del método descrito en el Capítulo 3 para el caso particular de estudio correspondiente a la comunidad de Huatacondo, con datos obtenidos el año 2014.

4.1. Datos disponibles

Los datos disponibles corresponden a 20 casas en que se tienen mediciones de contadores de pulsos, que reflejan el consumo energético de las viviendas con un tiempo de muestreo fijo de 15 minutos. Se puede tener una estimación de potencia promedio consumida tal como se indica en la Ecuación (7). Además de las mediciones para estas casas, se tienen mediciones de consumo total de la comunidad, con el mismo tiempo de muestreo.

Para aquellas casas en las que se instalaron los semáforos indicativos se tienen 39 días de mediciones base, que corresponden al mes de junio y mediados de julio de 2014. Para aquellas casas sin semáforos, se tienen 69 días de datos correspondientes a los meses de junio, julio, agosto, septiembre y mediados de octubre de 2014. La reducción de días se debe al pre-procesamiento de los datos, en que se eliminaron aquellos días en que las mediciones no se realizaron a intervalos regulares o que simplemente no contaban con datos.

En la Tabla 6 se resumen los días de consumo disponibles para cada mes, utilizados en el desarrollo del simulador.

Tabla 6. Mediciones de consumo disponibles

	Días de consumo disponibles
Junio	27
Julio	19
Agosto	2
Septiembre	11
Octubre	10

Además, se tienen 41 encuestas realizadas a 14 casas de la población en abril de 2014, en que se preguntó cuál sería el comportamiento de los usuarios respecto al uso de artefactos típicos que se encuentran en una casa, en un día normal y en casos en que se tenga una secuencia específica del semáforo (disponibles en el Anexo A). Se pregunta para bloques horarios entre las 07:00 y 00:00 horas, cuando se supone que puede haber gestión de demanda.

En la Tabla 7 se resumen las encuestas disponibles para el desarrollo del simulador.

Tabla 7. Encuestas disponibles

	Número de casas
Caso base	14
Semáforo 1	9
Semáforo 2	6
Semáforo 3	9
Semáforo 4	4

Con estos datos, se desarrolla el simulador de consumo, que entregue un consumo base y una respuesta asociada a la hora y color del semáforo. Ejecutando este simulador con semáforos aleatorios de entrada, se generan sets de datos de entrenamiento, test y validación para la obtención de un modelo a incorporar al EMS. Estos sets de datos se conforman por dos entradas (hora y color) y una salida (factor de respuesta ρ_L).

A continuación, se describirá la implementación del simulador propuesto en la Sección 3.4.

4.2. Simulador

El objetivo principal del simulador es la generación de datos con suficiente variabilidad para el entrenamiento del modelo Mamdani propuesto, ya que no se cuenta con datos de consumo con respuesta a la gestión de demanda en esta localidad como para poder realizar el entrenamiento de un modelo.

4.2.1. Consumo base

Analizando los consumos residenciales, se determinan 3 agrupaciones de consumos diarias, correspondiendo aproximadamente consumos bajos, medios y altos. En general, el consumo alto se da en la noche, mientras que el bajo y medio puede corresponder a la mañana/tarde o a la madrugada. Estas agrupaciones se pueden relacionar con las actividades realizadas por la población, teniendo momentos en que duermen, otros en que trabajan y finalmente aquellos en que se encuentran en sus casas.

Las características a utilizar que describen los niveles de potencia consumida para cada tiempo de muestreo son el valor mínimo, máximo y media del consumo. Minimizando la Ecuación (11) se obtienen los rangos que determinan las agrupaciones por casa, y para cada una de estas agrupaciones se obtendrá una cadena de Markov. En la Figura 22 se puede apreciar un ejemplo de los grupos obtenidos para una casa, indicando los límites dentro de los que será válida cada una de las tres cadenas de Markov. Se pueden identificar niveles de consumo bajos en la madrugada, altos en la mañana y medios/altos en la tarde/noche.




Figura 22. Agrupaciones obtenidas para una casa

Con los datos de potencia divididos para cada conjunto, se realiza el procedimiento para determinar el número de estados máximo de cada cadena, mencionado en el Capítulo 3.4.1. Se seleccionan valores de $t = 0.1$ y $p^* = 0.1$ y se opta por empezar el algoritmo con un número de estados $m = 8$. Los valores escogidos de t y p^* se escogieron de forma que no fueran muy estrictos para tener la posibilidad de tener un número razonable de estados que den más variabilidad a los consumos que serán generados. Con parámetros muy estrictos, se tendrían poca cantidad de estados, lo que limita enormemente las combinaciones posibles que puede generar una cadena. Con estos valores de t y p^* , se tiene que deben existir al menos $n_i = 150$ datos de transiciones para cada uno de los i estados de la cadena.

Para saber la pertenencia de un dato a un estado determinado se realiza el proceso de *clustering* mediante el algoritmo *k-means* para cada uno de los 3 grupos, utilizando la distancia euclidiana. Los resultados obtenidos respecto al número de estados se muestran en la Tabla 8, en que H representa al pueblo descontando las casas de las que se tienen mediciones individuales.

Tabla 8. Cantidad máxima de estados para cada cadena de Markov

Casa	Cantidad Máxima de Estados		
	S_1	S_2	S_3
1	3	2	3
2	8	8	3
3	1	5	3
4	1	2	4
5	2	1	3

6	3	2	3
7	4	5	5
8	2	1	4
9	4	4	2
10	2	2	5
H	4	5	3

Dada la metodología utilizada, se concluye que hay agrupaciones en las que existen pocos datos, o que hay estados (*clústers*) con pocos datos pertenecientes a ellos; es por esto que el proceso iterativo llega a que un estado es el máximo válido para representar los datos medidos.

Teniendo el número de estados para cada casa, se obtienen las cadenas de Markov con el cálculo de los estimadores de máxima verosimilitud de la Ecuación (8). Las cadenas formarán parte de la base de datos del simulador y se generan realizaciones a partir de ellas. Así, se tendrán 3 segmentos de perfiles de consumo, cada uno correspondiente a un intervalo del día, que serán concatenados para la obtención del perfil generado.

Como una medida de verificación de los datos generados, en la Tabla 9 se muestran el RMSE de la media de la potencia, el MAPE de la media de la potencia y el error de la media de la energía consumida diariamente, entre 69 días de datos generados y los datos medidos, tanto para las casas individuales como para el total de la comunidad. Aquí, *H* representa al pueblo descontando las casas de las que se tienen mediciones individuales, mientras que *Comunidad* representa a todo el pueblo.

Tabla 9. Medidas de verificación de los consumos base

Casa	Medidas de verificación			Medidos
	RMSE Potencia [W]	MAPE Potencia [%]	Error Energía [Wh]	Potencia Media Máxima [W]
1	52.2	19.9	-4.7	385.7
2	13.3	14.7	-4.1	108.7
3	53.1	9.4	-14.0	587.0
4	21.7	13.5	-5.1	182.0
5	24.8	21.5	83.5	172.8
6	68.2	14.5	12.0	539.2
7	15.0	8.2	7.8	179.4
8	47.5	23.3	21.1	370.7
9	56.9	18.3	27.4	350.7
10	61.2	19.0	-107.4	521.8
H	755.7	9.0	286.8	11287.0
Comunidad	819.3	7.3	303.4	13995

Como se puede apreciar, en la mayoría de los casos el error se encuentra en torno a los 50 [W] de potencia, lo que equivale a un par de ampolletas de bajo consumo o a un artefacto de baja potencia. Dependiendo de los niveles de consumo propios de cada casa, esta diferencia puede ser más o menos relevante. Analizando el valor MAPE para el total de la comunidad, que es el dato de interés para el desarrollo siguiente, se observa que es igual al 7.3% encuentran en torno al 20%; esto se debe principalmente a la baja cantidad de estados que se dan según el procedimiento de selección, teniendo mayores diferencias cuando existe una discretización menos fina (menos *clústers*). Se puede ver que esta diferencia se hace menor al agregar todas las potencias generadas y compararlas con el consumo de la comunidad.

Analizando la energía media consumida, se pueden identificar casos en que se simuló un mayor consumo energético diario promedio y viceversa. Al igual que los casos anteriores, esto se debe a la discretización en estados limitados.

A pesar de lo anterior, estas diferencias no deben ser vistas como negativas para el simulador, ya que el propósito de las cadenas de Markov en este trabajo es generar datos que tengan suficiente variabilidad como para considerar distintos escenarios.

Sumando todos los consumos base generados, se obtiene el consumo de potencia total, incluyendo aquellas viviendas sin monitoreo y los espacios de uso común (como son la iglesia, escuela, sede social y luminarias públicas). En la Figura 23, se muestra la potencia media de la comunidad (de 69 días) real y generada, por tiempo de muestreo.




Figura 23. Consumo medio medido y generado para la comunidad

Tanto en el consumo real como el generado de la comunidad, se pueden identificar tres niveles, correspondientes a la madrugada, mañana/tarde y tarde/noche, que concuerdan para ambos sets de datos. Esto verifica la selección de tres cadenas de Markov por casa, una para cada

nivel de consumo. Los niveles de consumo son más claros en los datos generados dado que el consumo generado H es de una escala mayor que la de casas individuales, por lo que su peso al calcular la media es mayor que los consumos generados para el resto de las casas.

A continuación, se mostrará la implementación de la respuesta del consumidor, que complementa el trabajo de esta sección.

4.2.2. Respuesta del consumidor

Para la generación y entrenamiento de las redes Bayesianas se utilizó el *Toolbox bnt* [7]. El set de datos a utilizar corresponde a los resultados de la encuesta de consumo aplicada en Huatacondo y cada muestra consiste en la hora, color, estado del artefacto en el caso base y la variación en el uso en el caso con semáforo. Con esto se tiene un vector de 4 elementos por muestra, y que corresponde a los nodos de la Figura 17. A 13 de las 14 casas se les preguntó por su respuesta ante dos semáforos, y a una de las casas sólo se le consultó por un semáforo. Siendo 18 horas consultadas y 13 artefactos, se totalizan 486 muestras para toda la comunidad, con los que serán entrenadas las redes Bayesianas.

Como no se tienen todas las combinaciones de hora, color y estado base posibles, que son nodos padres de la variación de estado, se tiene un set de datos incompletos. Por ejemplo, hubo casas a las que no se les preguntó cuál sería su reacción ante una luz roja a las 14 horas.

Para este set de datos incompletos se utiliza el algoritmo EM explicado en el Anexo B. Los parámetros *a priori* que se entregan a la red se calculan en base a todas las encuestas, y en los casos en que no se tengan datos, se utilizará la respuesta ante el color e independiente de la hora considerando todas las encuestas realizadas para el cálculo, esto siempre que la casa posea el artefacto en cuestión. Así, se tendrán 13 redes por casa, en que cada red tiene 2 tablas de probabilidades condicionales de interés para este trabajo (estado y variación), que suman 252 parámetros que completan estas CPT (*Conditional Probability Table*). Además, el algoritmo considera CPT para la hora y color, con lo que se tienen 21 otros parámetros, totalizando 273 probabilidades a encontrar. Al imponer $\sum_i p_i = 1$, estas probabilidades se reducen a 145.

En el caso de casas sin encuestas realizadas, se utilizará una red Bayesiana correspondiente a una respuesta promedio, en que el set de datos para el entrenamiento es la unión de las respuestas de todas las casas.

En la Tabla 10 se muestra la CPT de variación en el estado obtenida a partir de todas las encuestas para el televisor, el artefacto más común en la comunidad después de las ampolletas. Los valores indicados son de cambiar el estado del artefacto dada la hora, el color del semáforo y el estado en el caso base, es decir, la probabilidad de apagarlo si es que está prendido, y viceversa. Los valores de no cambiar el estado son los complementos para que la suma de ambas probabilidades sea igual a 1.

Tabla 10. Valores de la CPT del televisor para la comunidad

Hora	Tabla de probabilidad condicional de cambiar el estado base del televisor					
	Estado base: <i>off</i>			Estado base: <i>on</i>		
	Verde	Amarillo	Rojo	Verde	Amarillo	Rojo
7	0.0076	0	0.2846	0.0076	0.3333	0.2846
8	0	0	0	0.0076	0.3333	0.3333
9	0	0	0	0.5	0.4	0.5
10	0	0	0	0	0	0.5
11	0	0.1111	0	0	1	0.6
12	0	0	0	0	0.3333	0.5
13	0	0	0	0	0	0.5
14	0.0076	0	0	0	0.0769	1
15	0.0076	0	0	0	0.1667	0.5
16	0	0	0	0	0.2	0.5
17	0	0	0.2846	0	0.2	0.3333
18	0	0	0.2846	0	0	0.5
19	0	0	0.2846	0	0	0.5
20	0	0	0.2846	0	0.0769	0.5
21	0	0	0	0	0.0714	0.3750
22	0	0	0	0	0.0714	0.5
23	0	0	0	0	0	0.6
24	0	0	0	0	0	0.5

Como se puede apreciar en la Tabla 10, y según las encuestas, el televisor es más propenso a ser apagado que a ser prendido, especialmente cuando se indica la luz roja en el semáforo, habiendo horas en las que incluso se apagará con una total seguridad. La probabilidad de apagarlo aumenta cuando se indica la luz roja, y se hace casi nula cuando se muestra la luz verde.

Sin embargo, a la realización de la red hay que agregar el procedimiento descrito en la Sección 3.4.2: en caso de que los artefactos encendidos según la realización de las redes Bayesianas tengan un consumo mayor que el dado por la realización de consumo base, estos se van apagando iterativa y aleatoriamente. De los artefactos que quedan encendidos, y en base a un análisis de las encuestas que arrojó que a lo más un artefacto cambia a la vez, con lo se elige aleatoriamente una de las cargas y se utiliza su respuesta ante la luz y hora de entradas.

La hora de entrada al simulador es fija, por lo que queda determinar los semáforos, que son la variable manipulada del problema. La matriz de transición de estados para la cadena de Markov que genera los semáforos, se seleccionó de tal forma que todas las transiciones de estados tuvieran probabilidad igual a $1/3$, por lo que para cada bloque horario cualquiera de las

luces tiene igual probabilidad de ocurrencia, y así tener una alta aleatoriedad en la entrada de los datos.

En base a las redes Bayesianas presentadas, se generan consumos con gestión de demanda en dos escenarios de estudio, que pretenden plantear un caso cercano al actual, con un número limitado de casas con semáforo, y otro ideal, en que todas las casas habitadas permanentemente tienen acceso al semáforo:

- **Escenario 1:** 4 casas con semáforo instalado.
- **Escenario 2:** 25 casas con semáforo instalado.

En la Figura 24 se muestra una realización del simulador con consumo base y la respuesta asociada a un semáforo aleatorio para ambos casos.




Figura 24. Consumo con respuesta al DSM para 2 escenarios

Como es de esperarse, el nivel de respuesta es notoriamente mayor cuando hay más casas con acceso a las señales del semáforo, dado que una penetración de la estrategia de DSM en el 100% del pueblo tiene más probabilidades de generar los cambios deseados a nivel de comunidad porque hay más casas que potencialmente pueden reaccionar. De todas maneras en el escenario 1 se aprecia una respuesta, aunque comparativamente menor respecto al escenario 2 y apenas diferenciable del consumo base.

Con el simulador desarrollado, se pueden generar datos para el entrenamiento de un modelo difuso y calcular la respuesta de los usuarios, como se ve a continuación.

4.2.3. Factor de variación de consumo

Se realizan simulaciones con un tiempo de muestreo de 15 minutos para 360 días de consumos base y con respuesta ante la gestión de demanda, que conforman datos de entrenamiento. Para cada uno de los datos, se calcula el factor de variación de consumo según la Ecuación (17), en que $\rho_L(k, l) = P_{S_L}(k, l)/P_L(k)$. Con esto, se tiene el set de entradas y salidas que serán provistos al modelo.

En la Figura 25 se muestra el valor del factor ρ_L obtenido con los datos del simulador para la misma realización del semáforo de la sección anterior. En este ejemplo se puede ver claramente el impacto que tiene para el consumo del pueblo el que las 25 casas habitadas permanentemente tengan acceso a las señales del semáforo, pudiendo variar, en este caso, en hasta un 44.2% respecto a un consumo base, frente a un 13.2% en el caso en que hay 4 casas con semáforos.

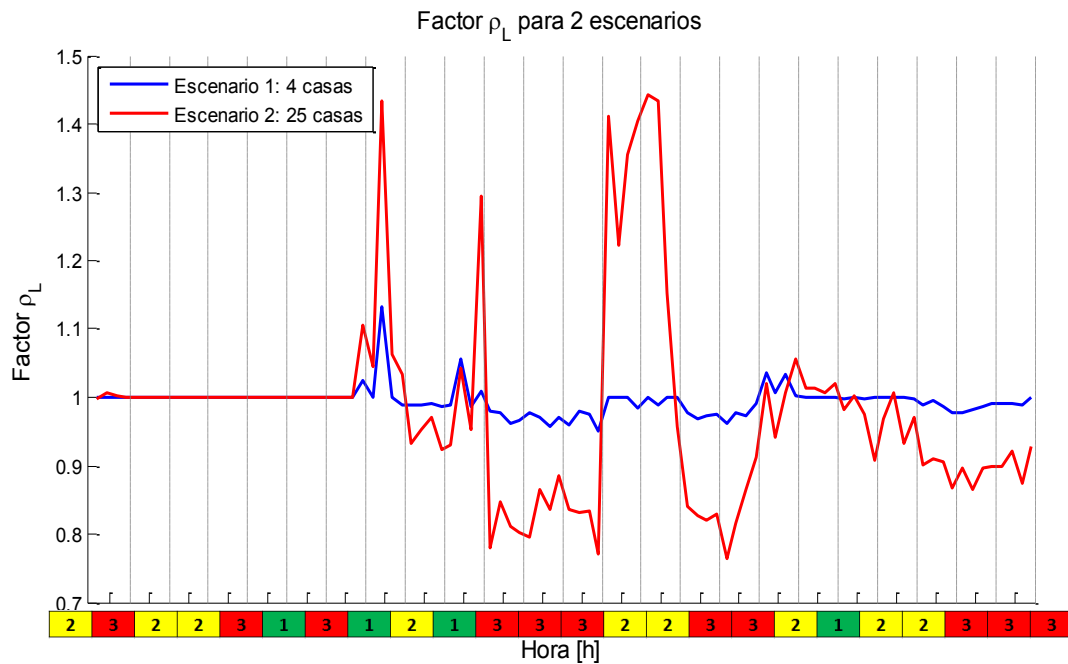


Figura 25. Realización de factores ρ_L para 2 casos

Se puede notar que en general los consumidores responden a las secuencias según lo deseado, aumentando sus consumos cuando hay luces verdes y disminuyéndolo cuando las luces son rojas. Cuando la luz es amarilla, este consumo puede aumentar, disminuir o mantenerse, dependiendo de la disposición que tengan los usuarios, y del resultado de la realización del simulador. Sin embargo, en el horario entre 13 y 14 horas se da un incremento de la respuesta de los usuarios para la luz amarilla. Esto se debe a que el simulador representa las respuestas de los usuarios, por lo que concluye que no todos los usuarios comprenden totalmente el funcionamiento del semáforo indicativo.

En la Figura 26 se aprecian los factores $\bar{\rho}_L$ medios para ambos escenarios, por tiempo de muestreo y según el color. Sea ρ_i la salida i del simulador generada al tener la hora K_i y el color

de la luz L_i como entradas, y N el número de datos generados que cumplen $K_i = k$ y $L_i = l$, entonces estos valores medios se calculan como:

$$\bar{\rho}_L(k, l) = \frac{1}{N} \sum_{i=1}^N \rho_i(K_i = k, L_i = l). \quad (24)$$




Figura 26. Factores ρ_L por color obtenidos por el valor medio

Se observa que se mantiene la tendencia de la realización mostrada en la Figura 25, existiendo un impacto mayor sobre el consumo de la micro-red en el escenario 2, por la cantidad de casas involucradas. En el bloque horario de las 7 a.m. se puede ver que se da un comportamiento no esperado, en que a pesar de que se indicada la luz roja, el consumo aumenta. Este comportamiento se debe a que, si bien se supuso gestión de demanda a las 7 de la mañana, en la práctica no se preguntó por distintos colores del semáforo para esa hora, sino que sólo el amarillo. Así, este comportamiento resultante está dado netamente por la inferencia de las redes Bayesianas, que no contó con una estimación inicial de parámetros adecuada.

Para evitar este comportamiento no intuitivo, se extenderá el supuesto previo del horario en que no hay gestión de demanda entre las 01:00 y 07:00 a.m.

Con estos resultados se pueden confirmar las observaciones hechas anteriormente, en que la luz verde hace aumentar el consumo, y la roja lo disminuye, existiendo una mayor elasticidad a aumentar que a disminuir el consumo. Como esto refleja las respuestas de las personas en las encuestas, se tiene que en general están bien informados del funcionamiento y objetivo del semáforo en la micro-red.

Además de poder generar datos sintéticos representativos de los consumidores, el simulador propuesto es flexible en cuanto a la cantidad de casas que responden al DSM, pudiendo ponerse en distintas situaciones. Además, permite variar las bases de datos tanto de matrices de transición de estados como las tablas de probabilidades condicionales, pudiendo generar datos bajo distintos escenarios respecto a la respuesta de los usuarios.

Teniendo los factores de consumo calculados, se procede a la obtención del modelo difuso tipo Mamdani que pretende modelar la respuesta de los usuarios.

4.3. Modelo difuso

Para el modelo difuso tipo Mamdani que busca modelar la respuesta de los consumidores, se consideran dos premisas o entradas: el color del semáforo y la hora del día. La estructura general del modelo es la mostrada en la Figura 19. Se debe definir la estructura de los modelos de tal forma que minimicen el error RMSE entre la salida estimada $\hat{\rho}_L$ y la salida objetivo ρ_L .

Como se ha mencionado anteriormente, no se considera gestión de demanda en horarios entre las 01:00 y 07:00 a.m., por lo que el conjunto se entrena sólo para el rango horario de las 08:00 a.m. y las 00:59 a.m.

Por cada instante de muestreo, el semáforo puede mostrar únicamente un color, por lo que estos conjuntos son triviales: se tienen 3 conjuntos para las luces verde, amarilla y roja, en que los colores tienen un grado de pertenencia igual a 1 cuando el color es indicado por el semáforo y 0 en el caso contrario. Este tipo de conjuntos, que se pueden apreciar en la Figura 19, tienen una función de pertenencia del tipo *singleton* y son excluyentes mutuamente.

Para el caso de la hora, se escogen funciones de pertenencia trapezoidales, ejemplificadas en la Figura 27.

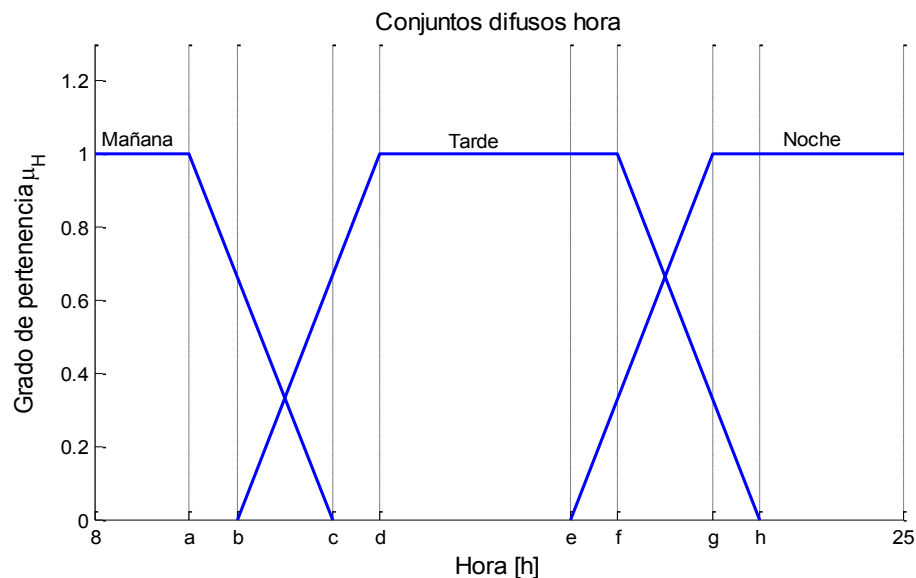


Figura 27. Ejemplo de conjuntos difusos para la hora

Como se aprecia, los conjuntos corresponden, en términos lingüísticos, a la *mañana*, *tarde* y *noche*, en que los conjuntos *mañana* y *noche* tienen 2 parámetros fijos en los extremos por conocimiento empírico (por ejemplo, definitivamente las 08:00 a.m. es una hora de la mañana) y 2 a ajustar mientras que el conjunto *tarde* cuenta con 4 parámetros. Estos parámetros a ajustar están denotados con las letras *a* a la *h*.

Se hacen pruebas variando el número de conjuntos, por lo que puede haber más conjuntos intermedios que compartan las características del conjunto *tarde* de este ejemplo, con 4 parámetros libres.

Se puede ver que el conjunto *noche* supera las 23:59; esto se debe a que el horario entre las 00:00 y las 00:59 tiene un comportamiento más cercano al de la noche que a la mañana, por lo que ese rango se considera como hora entre las 24:00 a las 24:59, de forma tal que pertenezcan al conjunto de la noche.

Para la salida, los conjuntos también se escogen trapezoidales, como se aprecia en la Figura 28, y con un significado lingüístico correspondiente a una respuesta el consumo *baja*, *mantiene* y *aumenta*, pudiendo agregarse conjuntos intermedios. Al igual que en el caso de la hora, los conjuntos *bajo* y *alto* tienen 2 parámetros fijos y 2 a ajustar, mientras que el *medio* posee 4 a ajustar, parámetros expresados con las letras *a* a la *h*. Los parámetros fijos A' y B' deben ser determinados por los valores máximos y mínimos, respectivamente, de respuesta obtenidos en la simulación para el conjunto de entrenamiento.

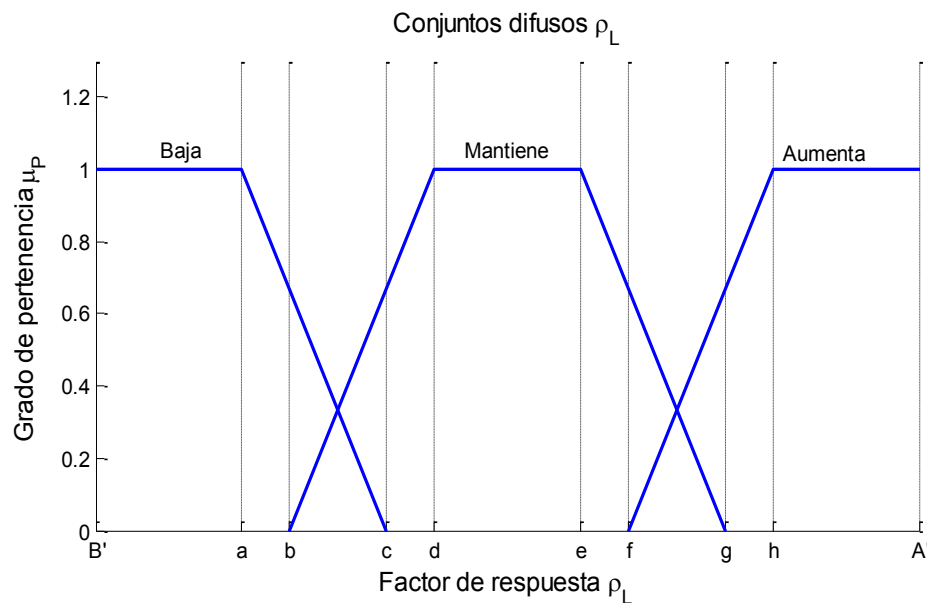


Figura 28. Ejemplo de conjuntos difusos para la respuesta ρ_L

Junto a los parámetros a ajustar de los conjuntos difusos de entrada y salida, se tienen las consecuencias de las reglas. Como en este caso no hay restricciones de qué color puede ser mostrado o no en las distintas horas, el número de reglas es $n_r = 3c_h$, con c_h el número de conjuntos para la hora. Estas n_r consecuencias se derivarán de la observación de la Figura 26,

con lo que se formará una base de reglas empírica de conocimiento experto, ya que las respuestas de los usuarios tienen una lógica bastante clara.

Como se explicó en la Sección 3.5.1, como *t-norma* se utiliza el operador mínimo, mientras que para la inferencia, se utiliza la composición *max-min*. Para la defusificación se hace uso del centro de gravedad.

De esta forma, los individuos tendrán representados en sus cromosomas los parámetros que determinan la forma de cada uno de los conjuntos trapezoidales. En el caso de 3 conjuntos de entrada y 3 de salida, son 16 los parámetros totales a ajustar, con los que se busca minimizar el error RMSE entre la salida del modelo y los consumos entregados por el simulador.

Cada escenario de estudio contará con un modelo tipo Mamdani. Esto porque, como se vio anteriormente, los valores de ρ_L varían para ambos casos y un modelo entrenado para un escenario no es válido en el otro.

Para una buena modelación es necesaria una entrada lo suficientemente variada que abarque el mayor rango posible de valores. Así, se generan secuencias de semáforos para los conjuntos de entrenamiento, test y validación. El conjunto de entrenamiento contará con 360 días simulados, mientras que los de test con 180 y validación con 180 días.

Del conjunto de entrenamiento obtenido con la simulación, se tienen que los puntos fijos de los conjuntos difusos: sean A'_i y B'_i los parámetros fijos del conjunto *alto* y *bajo* del escenario i , respectivamente, entonces: $A'_1 = 1.33, B'_1 = 0.85, A'_2 = 2.2$ y $B'_2 = 0.6$.

En la Tabla 11 y Tabla 12 se muestran errores de salida de los distintos modelos para el conjunto de validación en los escenarios 1 y 2, respectivamente. Como el factor ρ_L es adimensional, los errores no tienen unidades. Estos errores permiten comparar entre distintas estructuras de modelo tipo Mamdani, con lo que se puede seleccionar un modelo final. Los detalles de los modelos obtenidos se encuentran en el Anexo C.

Tabla 11. Errores de validación de modelos tipo Mamdani para el escenario 1

RMSE Validación		Escenario 1			
		# Conjuntos Hora			
		3	4	5	6
# Cjtos. Salida ρ_L	3	0.0360	0.0505	0.0513	0.0511
	5	0.0344	0.0366	0.0345	0.0387

Tabla 12. Errores de validación de modelos tipo Mamdani para el escenario 2

RMSE Validación		Escenario 2 # Conjuntos Hora			
		3	4	5	6
# Cjtos. Salida ρ_L	3	0.2025	0.1485	0.1419	0.1426
	5	0.1406	0.1506	0.1403	0.1257

En ambas tablas se encuentran destacados los modelos que tuvieron el menor error RMSE para el conjunto de validación. Para cada estructura, y dada la aleatoriedad del algoritmo genético, se realizaron 2 procesos de entrenamiento, escogiendo el modelo con menor RMSE. Se puede apreciar que existen errores significativos entre la modelación difusa tipo Mamdani y los datos del simulador. Lo anterior se debe a la forma obtenida para los conjuntos de la hora, en que se tienen grandes rangos de tiempo en que se activa únicamente una regla con un grado de cumplimiento constante, lo que genera que se tenga un conjunto de salida fijo en ese tiempo, obteniéndose una salida constante por el método del centroide.

En la Figura 29 se muestran gráficamente los resultados obtenidos con los mejores modelos tipo Mamdani para los distintos colores del semáforo en que se pueden ver los rangos horarios mencionados en que se mantiene un valor constante de ρ_L como salida, por ejemplo en la tarde o noche para ambos escenarios.




Figura 29. Factores ρ_L por color obtenidos con modelos tipo Mamdani

Dada la cantidad de reglas y las características de los conjuntos de entrada, se puede observar que el modelo entrega estimaciones relativamente suaves y constantes para ciertos segmentos horarios. En el escenario 2 se puede apreciar que entre las 9 y las 18 horas la estimación del factor de respuesta para el color verde y el amarillo es el mismo; esto se debe a que si bien las consecuencias de las reglas no son las mismas, los conjuntos de las consecuencias obtenidos con algoritmos genéticos son similares.

En el caso de aumentar el número de conjuntos difusos de la hora, se tendrán una mayor cantidad de reglas e intersecciones entre las funciones de pertenencia de la hora, con lo que se tendrá una mayor variabilidad y acercamiento de los valores estimados a los objetivos, pudiendo llegar al caso límite de tener 68 conjuntos para la hora (entre las 08:00 a.m. y las 00:59 a.m.) del tipo *singleton*, lo que en términos prácticos constituiría una tabla de referencia, con valores de respuesta para cada una de las combinaciones posibles (reglas).

El resultado de este modelo se compara con un modelo obtenido a partir de la Ecuación (24), calculado sobre los datos de entrenamiento. Este método es un símil del caso límite de un modelo tipo Mamdani con 68 conjuntos *singleton* para la entrada y 204 conjuntos *singleton* a la salida, correspondientes a la media de los valores de entrenamiento. Con esto se genera una tabla de referencia o *lookup table* de 68x3, que registra los factores de respuesta calculados para todas las combinaciones de colores y horas, por lo que para la estimación es necesario referirse a esta tabla. Los resultados generados por este modelo se aprecian en la Figura 30.




Figura 30. Factores ρ_L por color obtenidos con modelos *lookup table*

De la Figura 30 se puede observar la variabilidad en la expectativa de variación de consumo, especialmente notoria para distintos bloques horarios, diferenciándose por momentos del día, como son la mañana y tarde. Dentro de un mismo bloque horario, se puede esperar una respuesta similar de parte de los usuarios. En ambos modelos se puede apreciar que se mantiene la

tendencia esperada de que los usuarios aumenten su consumo cuando se tiene una luz de color verde indicada, y que lo disminuyan cuando esta es una luz roja. También se puede observar que la disposición a aumentar el consumo es mayor que a disminuirlo.

En la Tabla 13 se dan los errores RMSE para el modelo *lookup table* y se comparan con los errores de los modelos tipo Mamdani obtenidos para ambos escenarios.

Tabla 13. Errores de validación para la *lookup table* vs. Mamdani

RMSE Validación	Escenario 1	Escenario 2
<i>Lookup table</i>	0.0252	0.0653
Mamdani	0.0344	0.1257

Como se puede apreciar, en ambos casos la *lookup table* da mejores resultados que los modelos tipo Mamdani. Esto ocurre porque, al ser ambas entradas discretas, para cada combinación de hora y color se puede calcular un valor esperado. Como se sabe que la estimación óptima que minimiza el RMSE de una variable aleatoria, por medio de una constante, es su valor esperado, y que este valor esperado se puede estimar como la media de N realizaciones [48], entonces tiene sentido que la media sea un buen estimador de los factores de respuesta, e incluso es el estimador óptimo de la respuesta.

En la Figura 31 se muestran los factores ρ_L esperados para ambos escenarios de un día del conjunto de validación, tanto para los modelos tipo Mamdani como para los obtenidos con la *lookup table*, y se comparan con los valores de una realización del simulador.




Figura 31. Salidas de modelos tipo Mamdani y de la media para el conjunto de validación

Como se puede ver, ambos modelos reflejan la tendencia que tiene la comunidad de aumentar o disminuir el consumo, con el modelo tipo Mamdani mostrando un efecto menos drástico del DSM sobre la comunidad que el estimado por la *lookup table*; esto se puede apreciar especialmente en el escenario 2 a las 21 horas, en que el modelo de las medias alcanza mejor los *peaks* del factor ρ_L . De todas formas, no se puede tener una estimación que prediga exactamente los valores del factor de respuesta, dada la aleatoriedad de los datos generados.

Con estos modelos entrenados, se procede a determinar las entradas al EMS para realizar pruebas que determinen los beneficios de aplicar la metodología propuesta.

4.4. Implementación al EMS

Como entrada al EMS se tienen los factores de desplazamiento mínimo y máximo, S_{min} y S_{max} , respectivamente. Para la implementación propuesta, estos factores se consideran constantes para todos los días, por lo que el modelo tipo Mamdani no debe calcularlos en todo momento, sino que se puede obtener de forma previa una tabla con estos valores. Con el modelo ya entrenado, se le entrega como entradas vectores de hora y colores con todas las combinaciones posibles. Así, se tendrán 288 pares de entradas al modelo, en que cada par generará una salida determinística de variación del consumo ρ_L para el pueblo, construyendo una matriz de 96×3 a partir de la cual se pueden obtener las entradas al EMS, correspondientes al mínimo y máximo desplazamiento esperado para cada tiempo de muestreo, obtenidos según la Ecuación (23). En la Figura 32 se pueden ver estos desplazamientos esperados para cada caso de estudio, y se comparan con el modelo dado por la *lookup table*.

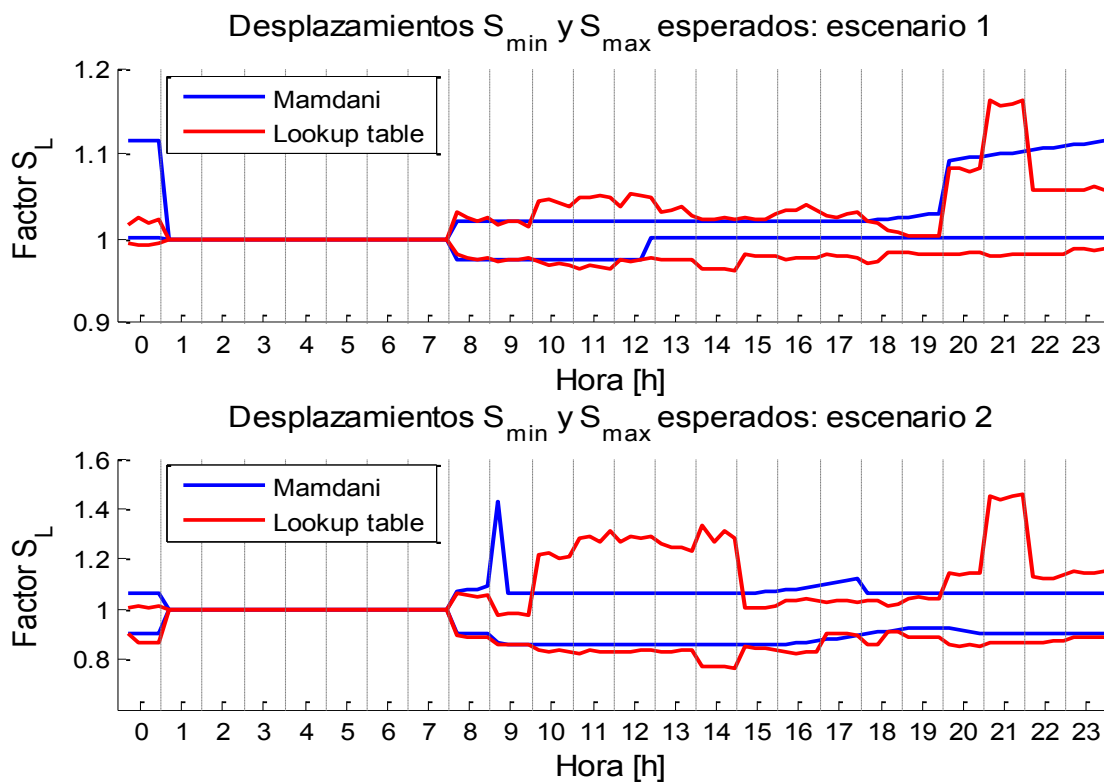


Figura 32. Factores de desplazamiento mínimo y máximo esperados

Se puede ver una tendencia de comportamiento similar para ambos casos, siendo diferente la escala del impacto de la variación sobre el consumo total y la poca capacidad de las estructuras de los modelos tipo Mamdani para representar los *peaks* en la respuesta. Un caso excepcional se da para el bloque de las 21 horas, en que según la *lookup table* se puede generar el máximo factor de desplazamiento diario. Esto no es reflejado por el modelo difuso, que entrega salidas más suaves.

El *software* en el que se realizarán las pruebas tiene una restricción en que los factores de desplazamiento deben cumplir que $S_{min}(k) \leq 1$ y $S_{max}(k) \geq 1 \forall k$. Así, independiente del resultado de la Figura 32, las entradas deben ser saturadas a 1 según corresponda. En la siguiente sección se detallan las pruebas a realizar.

4.5. Pruebas en el optimizador del EMS

Para determinar los beneficios de esta metodología en la micro-red, se realizan pruebas en el optimizador fuera de línea del EMS. El simulador se encuentra programado en *Java* y se le proporcionan las entradas a través de un archivo en formato *CSV*, que incluye los factores de desplazamiento máximos y mínimos de interés para esta aplicación.

4.5.1. Configuración de las pruebas

Se prueban los dos casos presentados, utilizando los resultados de los modelos entrenados tipo Mamdani y la *lookup table*. Para tener una cuantificación de los efectos de esta metodología, se proponen los siguientes pasos:

1. **Caso base:** Prueba sin gestión de demanda, en que da como entrada un consumo, potencia solar y eólica reales para 1 día y $S_{min}(k) = S_{max}(k) = 1 \forall k$. Esta prueba pretende ser un punto de comparación para los demás casos y busca determinar la operación de la micro-red y sus costos asociados en el caso en que no se pueda variar la respuesta de los usuarios.
2. **Prueba con factores de desplazamiento constantes:** Se realizan pruebas con las mismas entradas anteriores, con la diferencia en que los factores de desplazamiento mínimo y máximo son constantes y corresponden a un 5% y un 10% de variación, es decir, en un caso en que $S_{min}(k) = 0.95$ y $S_{max}(k) = 1.05 \forall k$, mientras que en el otro $S_{min}(k) = 0.90$ y $S_{max}(k) = 1.10 \forall k$.
3. **Prueba con modelo de respuesta:** En este caso, se entregan los factores S_{min} y S_{max} dados por el modelo obtenido y para los dos escenarios planteados, con 4 y 25 casas con semáforos instalados.

Con las dos últimas pruebas se determinarán los factores S_L deseados por la micro-red, y se tendrá el costo de operación en el “caso ideal” en que los usuarios responden exactamente como se desea, esto porque internamente la micro-red considera el consumo real como la multiplicación de estos factores y el consumo de entrada: $\tilde{P}_L(k) = S_L(k) \cdot P_L(k) \forall k$.

Las pruebas permitirán el análisis de las variaciones en el costo de operación para los distintos modelos obtenidos, además de la operación de la micro-red respecto al funcionamiento de las unidades generadoras e inversor.

Para las pruebas se utilizan 30 días de datos incluyendo potencia eólica, solar y consumo de la comunidad y 30 días en que no se considera potencia eólica. Como no se tienen datos eólicos asociados a las mismas fechas de los datos de consumo y potencia solar, se optó por utilizar un perfil de datos eólicos correspondiente a otro período, pero concordantes en la hora con el resto de los datos. Los sets de datos para potencia solar y consumo corresponden a mediciones del año 2014, entre marzo y abril, mientras que la potencia eólica corresponde a mediciones de agosto y septiembre de 2010.

Es de importancia recordar que además de los casos planteados por estos conjuntos de datos, se tienen dos escenarios, con 4 y 25 casas que responden ante las señales de gestión de demanda. Se incluyen los casos base y las pruebas con respuesta esperada del 5% y 10% constante para todo el periodo, totalizando 420 pruebas.

A continuación se muestran los resultados obtenidos con las configuraciones de las pruebas mencionadas.

4.5.2. Resultados

Las pruebas se realizan con un costo de diésel de CLP \$500 por litro, un costo de arranque de CLP \$1000 y el diésel apagado como condición inicial.

En la Figura 33 se observan ejemplificados los valores S_L deseados para un día de datos considerando potencia eólica y para los 2 escenarios planteados para el modelo difuso tipo Mamdani y el modelo consistente en la *lookup table*. En el Anexo C se pueden ver factores de desplazamiento S_L deseados para un día sin considerar potencia eólica.




Figura 33. Desplazamientos deseados por el EMS para un día con potencia eólica

Dependiendo del vector de rangos $[S_{min}, S_{max}]$ de entrada, es el desplazamiento de cargas deseado que entrega el EMS mediante el proceso de optimización. Este desplazamiento deseado está dado por la búsqueda de un óptimo de la función objetivo, y al dar como entradas restricciones menos exigentes, la función objetivo puede tomar valores que antes no eran factibles. En muchas ocasiones el optimizador entrega como factor de desplazamiento los límites de los rangos de entrada, lo que tiene la ventaja que se sabe, en teoría, y dados los datos del simulador, que esa respuesta se puede alcanzar con una luz específica.

En la Figura 34 se puede observar la operación de la micro-red al proveer el rango de desplazamiento esperado obtenido por el modelo tipo Mamdani y la *lookup table*, que se muestra en la Figura 32 para el escenario 2, con 25 casas receptoras al sistema de gestión de demanda.

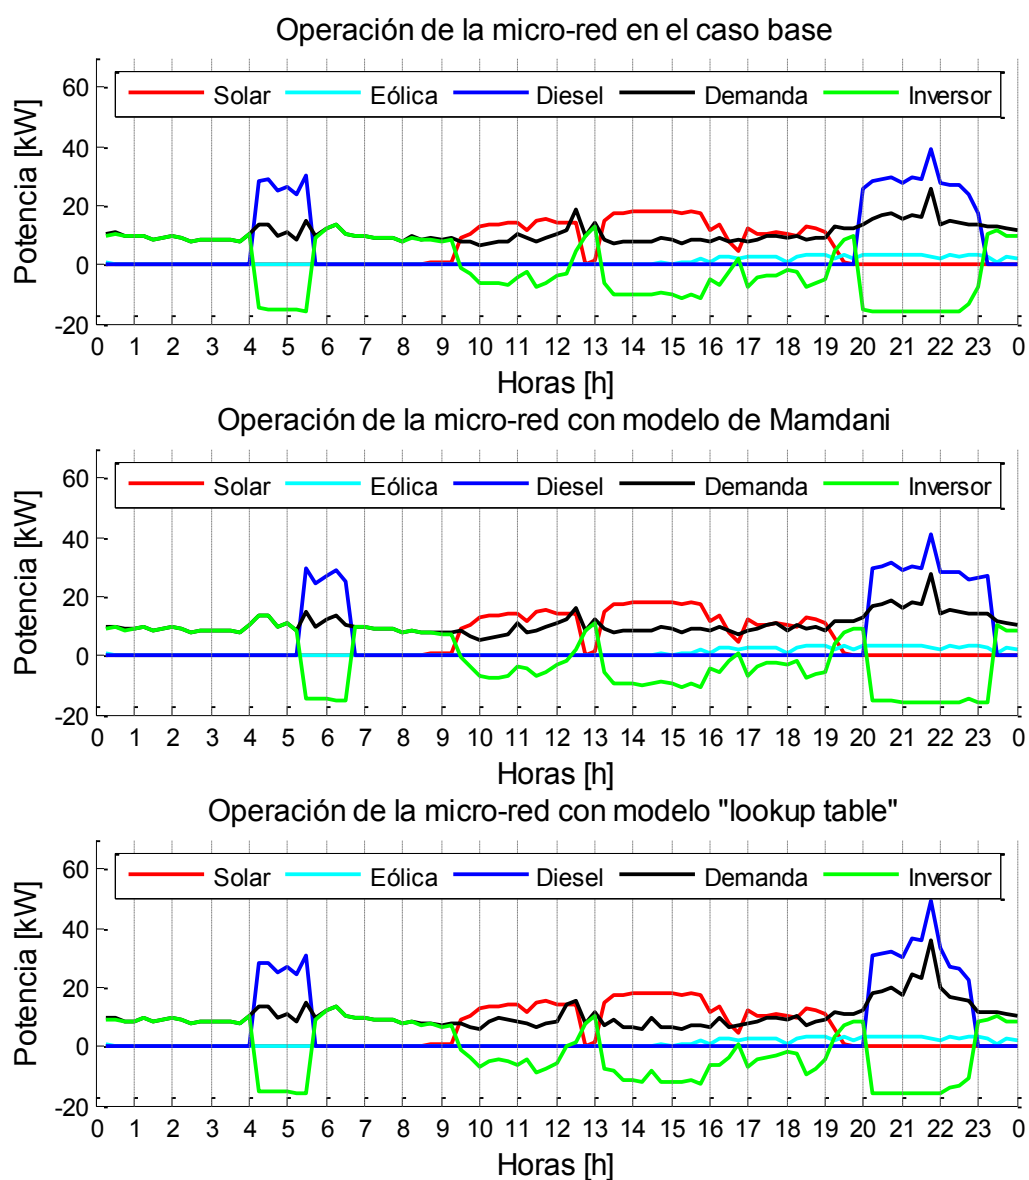


Figura 34. Operación de la micro-red para el escenario 2

Se puede apreciar cómo varía la demanda al aplicar los factores de desplazamiento deseados, de forma tal que optimice los costos de la micro-red. Esto se ve reflejado principalmente en el uso del generador diésel, variando su uso respecto al caso base en ciertas horas (como se aprecia entre las 20 y 23 horas).

En el Anexo C se muestran ejemplos de salidas para el escenario 1 y para el caso en que no se considera potencia eólica instalada, indicando la potencia de las unidades generadoras, inversor y demanda, además de los factores de desplazamiento deseados por la micro-red. En los casos simulados se puede observar que existe variación, en mayor o menor medida, del uso del diésel, dado por el cambio en el consumo demandado por el pueblo. Esto se resume en la Tabla 14, en que se dan los resultados promedio de costo del diésel (incluyendo costo de arranque y de generación) y el ahorro promedio generado. Los casos considerados es uno en que la micro-red cuenta con unidades de generación fotovoltaica, eólica y diésel; mientras que en un segundo caso se consideran unidades de generación fotovoltaica y diésel.

Tabla 14. Resumen de costos del combustible

Costo diésel (CLP) (Ahorro [%])		Caso 1: Promedio Solar/Eólica/Diésel	Caso 2: Promedio Solar/Diésel	Ahorro Promedio [%]
Caso base		\$20.909	\$16.487	-
5%		\$20.527 (1.83%)	\$16.098 (2.38%)	2.06%
10%		\$20.199 (3.43%)	\$15.505 (6.20%)	4.52%
Escenario 1 4 casas	Mamdani	\$20.871 (0.19%)	\$16.453 (0.22%)	0.19%
	Lookup table	\$20.825 (0.41%)	\$16.362 (0.79%)	0.56%
Escenario 2 25 casas	Mamdani	\$20.542 (1.75%)	\$16.094 (2.42%)	2.03%
	Lookup table	\$20.264 (3.09%)	\$15.806 (4.17%)	3.55%

Como se puede ver, y al igual que los resultados obtenidos en [8], al hacer menos estricta la restricción sobre S_L , se aumenta el espacio para una solución factible al problema de minimización, por lo que se encuentran puntos óptimos con un menor costo asociado a la función objetivo, sujeto a las mismas capacidades de generación. Uno de los factores de esta función es el costo del combustible, que es el analizado para estas pruebas.

Comparando con los factores de desplazamiento constantes, se tiene que aún el de 5% obtiene costos de combustible menores que en el escenario 1 para ambos modelos, y menores al escenario 2 con el modelo tipo Mamdani. Esto se debe a la flexibilidad que entrega al optimizador para incrementar o disminuir el consumo a voluntad dentro de ese rango. Sin embargo, el utilizar un rango de variación constante es un supuesto muy fuerte, ya que supone que la disposición a variar el consumo es la misma para cada hora del día, además de que se tiene

la misma disposición tanto para aumentar como para disminuir el consumo y que esas variaciones pueden ser logradas con el DSM instalado, sin considerar el número de casas que responderán. Como se pudo analizar de las encuestas y de los datos del simulador, esto no es así, y la disponibilidad de la gente varía en el tiempo, además de que en general son más propensos a aumentar el consumo que a bajarlo. Esta es la ventaja que tiene el entregar valores realistas de S_{min} y S_{max} .

De los resultados para ambos modelos, se concluye cuanto más casas participen activamente del sistema de gestión de la energía, tengan acceso al semáforo indicativo y respondan según lo declarado en las encuestas, y como indica el simulador, menores costos de combustible tiene la micro-red, asociados a un menor costo de operación.

Estos resultados tienen la limitación de que suponen que la gente responderá tal como desea el EMS.

5. Conclusiones y recomendaciones

En este trabajo se consideró el desarrollo de un simulador de consumo con y sin gestión de demanda representativo para la comunidad de Huatacondo, esto debido a la falta de datos de consumo con DSM en el caso de estudio. Los datos generados por este simulador permitieron el desarrollo de un modelo de repuesta de los usuarios ante la interfaz de DSM implementada. A partir de este modelo, se obtuvieron las entradas a proporcionar al EMS que definen el rango esperado que se tiene de respuesta de los usuarios ante las señales de gestión de demanda proporcionadas, limitando el espacio de solución para el problema de optimización.

Para el desarrollo de un simulador de consumo con y sin gestión de demanda, se utilizan datos históricos de consumo de la comunidad y resultados de encuestas de consumo para distintas secuencias del semáforo, que se supone que representan las acciones que tomarían los usuarios en los casos mencionados. Utilizando cadenas de Markov y redes Bayesianas, se entrena el simulador en base a los datos disponibles, cuyas entradas corresponden al color del semáforo y la hora asociada. Así, los datos generados de consumo base mantienen características respecto a los medidos, mientras que las respuestas generadas representan lo declarado por los usuarios en encuestas realizadas en la comunidad.

Entre las principales ventajas de este simulador, se cuentan la posibilidad de aumentar o disminuir el número de casas que tienen acceso al semáforo y que se asume que modificarán su comportamiento ante las señales del mismo. Además, se puede generar la cantidad de datos que se considere necesaria para la aplicación en un tiempo de simulación reducido (en el equipo utilizado, cerca de 14 minutos por año simulado), e introducir todo tipo de secuencias de semáforos para la realización de pruebas. Con esto, se puede tener una estimación de qué significan los colores verde, amarillo y rojo para la comunidad, en términos de consumo.

Se propusieron dos modelos de respuesta de los usuarios. El primero corresponde a un modelo tipo Mamdani que tiene como entradas la hora y el color del semáforo, mientras que el segundo consiste en la obtención de una *lookup table* en el cálculo de la media de los valores generados por el simulador por tiempo y color.

Se obtuvo que el modelo difuso tipo Mamdani no genera tan buenas estimaciones como un modelo que considera los valores medios para cada combinación de luz y hora. Esto se debe a que en este caso, el modelo obtenido con la media es un estimador óptimo de la variable aleatoria correspondiente a la respuesta ante la gestión de la demanda. Sin embargo, en el caso en que se desee optimizar el funcionamiento de la micro-red por medio de una solución analítica, un modelo de estructura conocida, como puede ser un modelo difuso, resulta promisorio si se incluye al proceso de optimización del EMS.

Como entradas al EMS se entregan los factores de desplazamiento mínimos y máximos para cada tiempo de muestreo, obtenidos evaluando el modelo derivado para cada instante y con las tres luces indicativas. Del modelo, los desplazamientos extremos determinan el rango esperado de repuesta y son provistos como entradas al EMS, limitando el factor de desplazamiento

deseado S_L a encontrar por el optimizador. Con esto se tiene seguridad de que el valor de S_L esté dentro de un rango en el que la comunidad puede responder a la estrategia de DSM instalada.

Las pruebas realizadas para ambos modelos incorporados al EMS mostraron que al instalar los semáforos en el pueblo se puede esperar una reducción de costos de consumo de combustible, mayores si son más las casas que tengan los semáforos instalados, llegando hasta un 3.55%. Si bien el ahorro generado es menor a que si se consideran factores de desplazamiento mínimos y máximos constantes para todo el día, se tiene como ventaja de que estos rangos son más realistas que el caso mencionado y se puede tener cierta seguridad de que pueden ser alcanzados por la población.

Los resultados pueden extenderse para otras épocas del año y comunidades, y pudiendo variar según cambien los pobladores de la comunidad, las compras de artefactos y la llegada del invierno boliviano, entre otros factores. Sin embargo, la misma metodología propuesta puede ser aplicada en otras temporadas, y en el futuro, a otras micro-redes que cuenten con un DSM igual o similar al de Huatacondo.

5.1. Trabajo futuro

Como trabajo futuro, se propone entrenar nuevos modelos, en lo posible con datos reales, que sean válidos para distintas épocas del año, lo que debe ser acompañado de un estudio que indique cuáles son estas épocas.

Para disminuir aún más los costos de operación de la micro-red, se propone el desarrollo de un modelo que determine qué luz deberán indicar los semáforos para generar la respuesta deseada por el optimizador del EMS. Con esto se pretende minimizar el error entre la demanda esperada y la real, situación que incrementa los costos de operación de la micro-red.

Relacionado con lo anterior, se plantea la incorporación de los modelos derivados al proceso de optimización, de forma que la obtención del factor de desplazamiento deseado S_L esté restringida a alguno de los valores que puede tomar con uno de los tres colores de luces, es decir, que el factor S_L no pertenezca a un rango continuo, sino que a un set de 3 elementos por cada tiempo de muestreo k .

De no contar con datos suficientes, y como mejoras al simulador, se pueden agregar otros factores, como pueden ser la temporada, el día (de semana, fin de semana o festivo), si hay fiestas o no y el clima. Lo mismo para el modelo a entrenar, que idealmente debe ser obtenido a partir de datos reales. Con esto se pretende tener factores de desplazamiento dinámicos que estimen la respuesta de los usuarios en distintas situaciones, con el fin de tener rangos más certeros para ser considerados en el optimizador.

Si la comunidad decidiera cambiar el sistema de gestión de la energía por alguno con incentivos económicos, se podría utilizar como base la metodología propuesta en este trabajo, variando, en el caso del simulador, el trabajo realizado con redes Bayesianas. En el caso del modelo tipo Mamdani se tendría que agregar como entrada el precio de la energía y descartando el color.

6. Bibliografía

- [1] Fundación Chile, “Comunidades aisladas podrán acceder a energía de bajo costo y autogestionada,” [Online] 2014, <http://www.fundacionchile.com/ene-detalle-noticia-area/detalle-noticia-area.index/3961/comunidades-aisladas-podran-acceder-a-energia-de-bajo-costo-y-autogestionada>. Accessed: 30 de junio de 2014.
- [2] K. Ubilla, G.A. Jimenez-Estevez, R. Hernandez, L. Reyes-Chamorro, C. Hernandez, B. Severino and R. Palma-Behnke, “Smart Microgrids as a Solution for Rural Electrification: Ensuring Long-Term Sustainability Through Cadastre and Business Models,” *IEEE Transactions on Sustainable Energy*, vol. 5, no. 4, pp. 1310-1318, 2014.
- [3] S. Jain, and V. Agarwal, “An Integrated Hybrid Power Supply for Distributed Generation Applications Fed by Nonconventional Energy Sources,” *IEEE Transactions on Energy Conversion*, vol. 23, no. 2, pp. 622-631, 2008.
- [4] R.H. Lasseter, “MicroGrids,” *Power Engineering Society Winter Meeting*, vol. 1, pp.305-308, 2002.
- [5] J. Han, and M. Piette, “Solutions for summer electric power shortages: Demand response and its applications in air conditioning and refrigerating systems,” *Refrigerations, Air Conditioning and Electric Power Machinery*, vol. 29, no. 1, pp. 1-4, 2008.
- [6] C.W. Gellings, “The Concept of Demand-Side Management for Electric Utilities,” *Proceedings of the IEEE*, vol. 73, No. 10, pp. 1468-1470, 1985.
- [7] K. Murphy. (2007). *Bayes Net Toolbox for Matlab* [Online]. Available: <https://code.google.com/p/bnt>.
- [8] R. Palma-Behnke, C. Benavides, F. Lanas, B. Severino, L. Reyes, J. Llanos, and D. Sáez, “A Microgrid Energy Management System Based on the Rolling Horizon Strategy,” *IEEE Transactions on Smart Grid*, vol. 4, pp. 996-1006, 2013.
- [9] C.V. Nayar, W.B. Lawrance, and S.J. Phillips, “Solar/Wind/Diesel Hybrid Energy Systems for Remote Areas,” *Proceedings of the 24th Intersociety Energy Conversion Engineering Conference*, vol. 4, pp. 2029-2034, 1989.
- [10] N. Hatziargyriou, H. Asano, R. Iravani, and V. Marnay, “Microgrids,” *IEEE Power & Energy Magazine*, 2007.
- [11] D. Olivares, A. Mehrizi-Sani, A. Etemadi, C. Cañizares, R. Iravani, M. Kazerani, A. Hajimiragha, O. Gomis-Bellmunt, M. Saeedifard, R. Palma-Behnke, G. Jimenez-Estevez and N. Hatziargyriou, “Trends in Microgrid Control,” *IEEE Transactions on Smart Grid*, vol. 5, no. 4, pp. 1905-1919, 2014.
- [12] Qing Qin, Zhixin Chen, and Xiaohui Wang, “Overview of Micro-grid Energy Management System Research Status,” *IEEE Power Engineering and Automation Conference*, pp. 1-4, 2012.
- [13] Huibin Sui, Ying Sun, and Wei-Jen Lee, “A Demand Side Management Model Based on Advanced Metering Infrastructure,” *4th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies*, pp. 1586-1589, 2011.

- [14] M.H. Albadi, and E.F. El-Saadany, "Demand Response in Electricity Markets: An Overview," *IEEE Power Engineering Society General Meeting*, pp. 1-5, 2007.
- [15] E. Et-Tolba, M. Maaroufi, and M. Ouassaid, "Demand Side Management Algorithms and Modeling in Smart Grids. A Customer's Behavior Based Study," *International Renewable and Sustainable Energy Conference*, pp. 531-536, 2013.
- [16] Chen Xiang-ting, Zhou Yu-hui, Duan Wei, Tang Jie-bin, and Guo Yuxiao, "Design of Intelligent Demand Side Management System Respond to Varieties of Factors," *China International Conference on Electricity Distribution (CICED)*, pp. 1-5, 2010.
- [17] A. Bagherian, and S.M. Moghaddas, "A developed Energy Management System for a Microgrid in the Competitive Electricity Market," *IEEE Bucharest Power Tech Conference*, pp. 1-6, 2009.
- [18] A. Zaidi, and F. Kupzog, "Microgrid Automation – A Self-Configuring Approach," *12th IEEE International Multitopic Conference*, pp. 565-570, 2008.
- [19] A. Gabaldon, A. Molina, C. Roldan, J.A. Fuentes, E. Gómez, I.J. Ramírez-Rosado, P. Lara, J.A. Domínguez, E. García-Garrido, and E. Tarancon, "Assessment and Simulation of Demand-Side Management Potential in Urban Power Distribution Networks," *IEEE Bologna Power Tech Conference Proceedings*, vol. 4, pp. 1-5, 2003.
- [20] Jianxue Wang, Xifan Wang, and Xiaoying Ding, "The Forward Contract Model of Interruptible Load in Power Market," *Transmission and Distribution Conference and Exhibition*, pp. 1-5, 2005.
- [21] D.M. Keane, and A. Goett, "Voluntary residential time-of-use rates: lessons learned from Pacific Gas and Electric Company's experiment," *IEEE Transactions on Power Systems*, vol. 13, no. 4, pp. 1764-1768, 1988.
- [22] M. Ann-Piette, G. Ghatikar, S. Kiliccote, D. Watson, E. Koch, and D. Hennage, "Design and Operation of an Open, Interoperable Automated Demand Response Infrastructure for Commercial Buildings," *Journal of Computing Science and Information Engineering*, vol. 2, no. 2, pp. 1-9, 2009.
- [23] A. Mohsenian-Rad, and A. Leon-Garcia, "Optimal Residential Load Control with Price Prediction in Real-Time Electricity Pricing Environments," *IEEE Transactions on Smart Grid*, vol. 1, No. 2, pp. 120-133, 2010.
- [24] R. Palma-Behnke, D. Ortiz, L. Reyes, G. Jiménez-Estévez, and N. Garrido, "A Social SCADA Approach for a Renewable based Microgrid – The Huatacondo Project –," *IEEE Power and Energy Society General Meeting*, pp. 1-7, 2011.
- [25] W. Radziszewska and Z. Nahorski, "Simulation of energy consumption in a microgrid for demand side management by scheduling," *Proceedings of the 2013 Federated Conference on Computer Science and Information Systems*, pp. 679-682, 2013.
- [26] M. Armstrong, M. Swinton, H. Ribberink, Ian Beausoleil-Morrison and J. Millette, "Synthetically derived profiles for representing occupant-driven electric loads in Canadian housing," *Journal of Building Performance Simulation*, vol. 2, no. 1, pp. 15-30, 2009.
- [27] E. Carpaneto and G. Chicco, "Probabilistic characterization of the aggregated residential load patterns," *IET Generation, Transmission & Distribution*, vol. 2, no. 3, pp. 373-382, 2008.

- [28] J. Paatero and P. Lund, "A model for generation household electricity load profiles," *International Journal of Energy Research*, vol. 30, no. 5, pp. 573-290, 2006.
- [29] J. Widén, A. Nilsson and E. Wäckelgård, "A combined Markov-chain and bottom-up approach to modelling of domestic lighting demand," *Energy and Buildings*, vol. 41, pp. 1001-1012, 2009.
- [30] J. Widén and E. Wäckelgård, "A high-resolution stochastic model of domestic activity patterns and electricity demand," *Applied Energy*, vol. 87, pp. 1880-1892, 2010.
- [31] A. Cornejo, J. Morales, and L. Baringo, "Real-Time Demand Response Model," *IEEE Transactions on Smart Grid*, vol. 1, no. 3, pp. 236-242, 2010.
- [32] Fang Yuan Xu, Xue Wang, Loi Lei Lai, and Chun Sing Lai, "Agent-based Modeling and Neural Network for Residential Customer Demand Response," *IEEE International Conference on Systems, Man, and Cybernetics*, pp. 1312-1316, 2013.
- [33] D.S. Kirschen, G. Strbac, P. Cumperayot, and D. de Paiva, "Factoring the Elasticity of Demand in Electricity Prices," *IEEE Transactions on Power Systems*, vol. 15, no. 2, pp. 612-617, 2000.
- [34] D.S. Kirschen, "Demand-side view of electricity markets," *IEEE Transactions on Power Systems*, vol. 18, no. 2, pp. 520-527, 2003.
- [35] A. Basu, T. Panigrahi, S. Chowdhury, S. P. Chowdhury, N. Chakraborty, A. Sinha and Y. Song, "Key Energy Management Issues of Setting Market Clearing Price (MCP) in Micro-Grid Scenario," *Universities Power Engineering Conference*, pp. 854-860, 2007.
- [36] H. Aalami, G.R. Yousefi, and M. Parsa Moghadam, "Demand Response Model Considering EDRP and TOU Programs," *Transmission and Distribution Conference and Exposition*, pp. 1-6, 2008.
- [37] T. Holtschneider, and I. Erlich, "Modeling demand response of consumers to incentives using fuzzy systems," *IEEE Power and Energy Society General Meeting*, pp. 1-8, 2012.
- [38] F. Ávila, "Diseño de un Sistema de Gestión de Demanda Basado en Lógica Difusa para Micro-Redes," *Memoria para optar al Título de Ingeniera Civil Electricista*, 2013.
- [39] N. Garrido, "Análisis y Evaluación Ambiental, Proyecto Sistema de Energización Sustentable para Huatacondo, Comuna de Pozo Almonte, Región de Tarapacá," *Memoria para Optar al Título de Geógrafa*, 2010.
- [40] C. Alvial-Palavicino, N. Garrido-Echeverría, G. Jiménez-Estévez, L. Reyes, and R. 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, 2011.
- [41] T.W. Anderson and L. A. Goodman, "Statistical Inference about Markov Chains," *The Annals of Mathematical Statistics*, pp. 89-110, 1957.
- [42] H. Navarrete, "Caracterización estadística del perfil de uso de baterías para el pronóstico del estado de carga," *Memoria para optar al Título de Ingeniero Civil Eléctrico*, 2014.
- [43] Edenor, "Consumo de Artefactos Eléctricos" [Online] 2014, http://www.edenor.com.ar/cms/SP/CLI/HOG/USO_consumo.html. Accessed: 25 de agosto de 2014.

- [44] I. Ben-Gal, "Bayesian Networks," in F. Ruggeri, F. Faltin and R. Kennet *Encyclopedia of Statistics in Quality and Reliability*, Wiley & Sons, 2007.
- [45] K. Korb and A. Nicholson, "Introducing Bayesian Networks," in *Bayesian Artificial Intelligence*, 2nd ed. Boca Raton: Chapman & Hall/CRC, 2004, ch. 2, sec. 2.3, pp. 33-34.
- [46] A. Dempster, N. Laird and D. Rubin, "Maximum Likelihood from Incomplete Data via the EM Algorithm," *Journal of the Royal Statistical Society*, vol. 39, no. 1, pp. 1-38, 1977.
- [47] E. 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, 1975.
- [48] G. González, "Estimación de una Variable Aleatoria y de un Proceso Estocástico," in *Introducción a los Procesos Estocásticos*, pp. 51-53, 2014.
- [49] D. Levin, Y. Peres and E. Wilmer, "Introduction to Finite Markov Chains," in *Markov Chains and Mixing Times*, pp.1-2.
- [50] M. Mitchell, "Elements of Genetic Algorithms," in *An Introduction to Genetic Algorithms*, 1st ed. MIT Press, 1998, ch. 1, sec. 1.5, pp. 7-10.
- [51] MathWorks "k-means clustering," [Online] 2014, <http://www.mathworks.com/help/stats/kmeans.html>. Accessed: 01 de diciembre de 2014.
- [52] Z. Ghahramani, "An Introduction to Hidden Markov Models and Bayesian Networks," *International Journal of Patter Recognition and Artificial Intelligence*, vol. 15, no. 1, pp. 9-42, 2001.
- [53] R. Babuška, "Linguistic Fuzzy Models" in *Fuzzy Modeling for Control*, 1st ed. Kluwer Academic Publishers, 1998, ch. 2, sec. 2.1, pp. 10-21.
- [54] L. Wang, "What Are Fuzzy Systems?," in *A Course in Fuzzy Systems and Control*, Prentice-Hall International, pp. 7.

A. Anexo: Encuestas

A.1. Encuesta de consumo

Se presenta un ejemplo de la encuesta de consumo aplicada a las viviendas, asociada a los semáforos presentados, en este caso al semáforo número 2.

FVA

Nombre: Yolanda

Casa (ubicación en el mapa): Casa 3 teléfono.

Caso: Base Semáforo 1 Semáforo 2 Semáforo 3 Semáforo 4


Hora	Refrigerador	Horno Eléctrico	Hervidor	TV	Plancha	Lavadora	Radio	Microondas	Ampolleta	Otros (1)	Otros (2)	Otros (3)
07												
08			X									
09	X		X	X								
10	X			X								
11	X		X	X								
12			X									
13	X			X								
14	X			X								
15	X			X								
16	X			X								
17	X			X								
18	X			X					X			
19	X			X					X			
20	X			X					X			
21	X			X					X			
22	X			X					X			
23	X			X					X			
24	X			X					X			

A.2. Semáforos presentados a la comunidad

Se presentan los semáforos presentados en las encuestas realizadas a la población.


Semáforo 1

Soleado




Semáforo 2

Nublado




Semáforo 3

No Típico



Semáforo 4

No Típico



B. Anexo: Herramientas usadas en el desarrollo

En esta sección, se explicarán las herramientas utilizadas en la implementación de la propuesta de esta memoria.

B.1. Cadenas de Markov

Una cadena de Markov finita y discreta, consiste en un proceso que se mueve entre elementos de un conjunto finito Ω [49]. Cada uno de estos elementos se conoce como *estado*, y lo que representa cada estado debe ser definido según la aplicación. Si se tiene que i es el estado actual, la determinación de cuál será el siguiente estado al que se moverá el proceso se hace en base a una probabilidad $P(i, \cdot)$. Como se puede ver, una de las características de esta transición es que sólo depende del estado actual, independiente de los estados que haya tomado el proceso anteriormente: a esto se le conoce como la *propiedad de Markov*.

Con esta configuración, se tiene una cadena de Markov con espacio de estados Ω y matriz de transición de estados (MTE) P . La MTE agrupa todas las probabilidades de transición entre los estados, en que las filas corresponden al estado i en el tiempo actual k , y las columnas a los posibles estados j en el tiempo $(k + 1)$. En la Ecuación (25) se puede ver la estructura de la MTE para una cadena de m estados, en que la probabilidad de transición de un estado i a un estado j está representada por p_{ij} .

$$P = \begin{pmatrix} p_{11} & \cdots & p_{1m} \\ \vdots & \ddots & \vdots \\ p_{m1} & \cdots & p_{mm} \end{pmatrix}. \quad (25)$$

La MTE cumple que las probabilidades $p_{ij} \geq 0 \forall i, j$, y para cada fila i , se cumple que:

$$\sum_{j=1}^m p_{ij} = 1. \quad (26)$$

Es decir, que a partir del estado i debe necesariamente realizar una transición a uno de los estados $j = 1 \dots m$.

Para obtener los valores de los elementos de la MTE a partir de datos reales, una estrategia utilizada consiste en registrar el número de datos que pertenecen al estado i en el tiempo k y que además pertenecen al estado j en el tiempo $(k + 1)$. Esta cantidad de datos se denota como n_{ij} , y en [41] se demuestra que el estimador de máxima verosimilitud de p_{ij} es:

$$\hat{p}_{ij} = \frac{n_{ij}}{\sum_{j=1}^m n_{ij}}. \quad (27)$$

B.1.1. Selección de cantidad de estados

En esta sección se detalla el procedimiento desarrollado en [42] para la determinación del número máximo de estados de una cadena tal que sean representativos y cumplan con ciertos criterios de diseño. En primer lugar, se debe dar un valor de $t \in [0,1]$ y $p^* \in [0,1]$ deseados, en que p^* indica la máxima probabilidad que se puede aceptar que el estimador de máxima verosimilitud varíe en t respecto a su valor real:

$$P\{|\hat{p}_{ij} - p_{ij}| \geq t\} \leq p^*. \quad (28)$$

Se debe verificar que para cada estado se cumpla la desigualdad anterior. Definiendo $n_i = \sum_{j=1}^m n_{ij}$, se tienen cotas superiores para la probabilidad de que la diferencia entre el estimador y el valor real de p_{ij} :

$$P\{|\hat{p}_{ij} - p_{ij}| \geq t\} \leq 2e^{-2n_it^2}, \quad (29)$$

$$P\{|\hat{p}_{ij} - p_{ij}| \geq t\} \leq \frac{1}{4n_it^2}. \quad (30)$$

Agregando que la probabilidad debe ser menor o igual a 1, se obtiene que la cota superior, dado t y n_i , es:

$$c(n_i) = \min\left\{1, 2e^{-2n_it^2}, \frac{1}{4n_it^2}\right\}. \quad (31)$$

Así, para cumplir los requerimientos de diseño, se debe satisfacer que para cada uno de los i estados de partida de MTE se cumpla que $c(n_i) \leq p^*$. Esto se realiza mediante un proceso iterativo, en que se parte con una cantidad de estados alta, y esta se va reduciendo hasta que se cumpla la condición mencionada, obteniendo así una máxima cantidad para la cadena de Markov.

B.2. Algoritmos genéticos

Los algoritmos genéticos se basan en la biología y tienen su principal aplicación para la optimización de funciones, buscando los parámetros que la maximicen [50]. La ventaja que presentan frente a otros métodos radica en que es menos probable que entreguen como solución máximos locales, dados los términos estocásticos que son parte del algoritmo.

Se tiene una población de cromosomas, en que cada uno de ellos consiste en un vector con valores binarios (secuencia) que representan los parámetros de la función. Si el problema es de parámetros reales, deben ser pasados a binario. Por su parte, cada uno de estos cromosomas tienen asociado un *fitness*, que es la función objetivo evaluada con los parámetros del cromosoma.

Los principales operadores del algoritmo son:

- **Selección:** Se elige un par de cromosomas de la población para su reproducción. Mientras mejor sea su *fitness*, más probabilidad tendrá de ser seleccionado.
- **Crossover:** Decide aleatoriamente si intercambiar o no sub-secuencias de los cromosomas padres seleccionados.
- **Mutación:** Aleatoriamente, y con una baja probabilidad, cambia un bit del cromosoma.

El proceso a seguir para ejecutar los algoritmos genéticos, se puede resumir en los siguientes pasos, que en su conjunto consisten en una generación:

1. Crear aleatoriamente n cromosomas iniciales.
2. Calcular el *fitness* para cada cromosoma.
3. Obtener una nueva población:
 - a. Seleccionar un par de padres de la población actual.
 - b. Cambiar, con probabilidad p_c , sub-secuencias de los cromosomas padres, definidas por uno o varios puntos.
 - c. Mutar cromosomas hijos, con probabilidad p_m .
4. Reemplazar la población actual por la nueva.
5. Repetir pasos 2-4.

El algoritmo finaliza cuando se han cumplido ciertos criterios de término, como el número de generaciones o la variación en la función *fitness*. El valor final entregado consiste en el mejor cromosoma (mejor función *fitness*) de la última generación.

B.3. Algoritmo *k-means*

Es un algoritmo iterativo, que asigna n observaciones a exactamente k *clusters* definidos por centroides, con $n \geq k$ [51]. El valor k es seleccionado previamente. Se busca encontrar las agrupaciones que minimicen la distancia (euclidiana, de hamming, etc.) entre los puntos pertenecientes a un mismo *cluster*:

$$\operatorname{argmin}_S \sum_{i=1}^k \sum_{x \in S_i} \|x - \mu_i\|^2, \quad (32)$$

donde μ_i es la media entre todos los $x \in S_i$ y corresponde al centroide.

El proceso cuenta con los siguientes pasos:

1. Elegir k centroides iniciales aleatoriamente.
2. Calcular las distancias de cada observación al centroide.
3. Asignar las observaciones. Se pueden seguir dos métodos:
 - a. *Batch*: Asigna las observaciones al *cluster* más cercano.
 - b. *Online*: Individualmente, asigna la observación al *cluster* que minimiza las distancias *intra-clusters*.
4. Calcular el promedio de las observaciones pertenecientes a un mismo *cluster*, con lo que se obtienen k nuevos centroides.

5. Repetir pasos 2-4.

El algoritmo finaliza cuando se hayan cumplido ciertos criterios de término, como un cierto número de iteraciones, o no variar significativamente la suma de las distancias.

B.4. Redes Bayesianas

Las redes Bayesianas consisten en modelos gráficos probabilísticos *direccionados* y *acíclicos* [45]. Estos gráficos representan dependencias entre variables aleatorias, en que estas variables son representadas por nodos, y sus dependencias, con uniones direccionadas (flechas); la ausencia de uniones representa la independencia condicional entre variables. Un nodo que dependa de otro se conoce como *hijo*, y el que genera esa dependencia se conoce como *padre*. El que sea *acíclico* quiere decir que no permite ciclos cerrados, o de realimentación, es decir, un nodo *hijo* no puede ser *padre* de su *padre* (o *ancestros*).

Cada nodo puede tomar distintos valores (ya sea binarios o multinomiales) y tiene probabilidades asociadas a estos valores, con dependencias de sus nodos *padres*. A partir de estas probabilidades, se da lugar a las Tablas de Probabilidades Condicionales (CPT), ejemplificadas posteriormente.

En estas redes se pueden definir tres tipos de nodos:

- Interrogantes (*query*): de los cuales interesa tener una estimación o valor.
- Evidencias (*evidence*): que consisten en las entradas observables a la red.

Estas redes son flexibles en cuanto a la dirección de razonamiento; dependiendo del objetivo, un nodo puede tener distintos roles. Es decir, se pueden observar las consecuencias y calcular las causas probables (*diagnóstico*), o bien se pueden observar las causas y calcular las probabilidades de las consecuencias (*pronóstico*). En la Figura 35 se pueden observar las dos principales direcciones de razonamiento en una red Bayesiana.

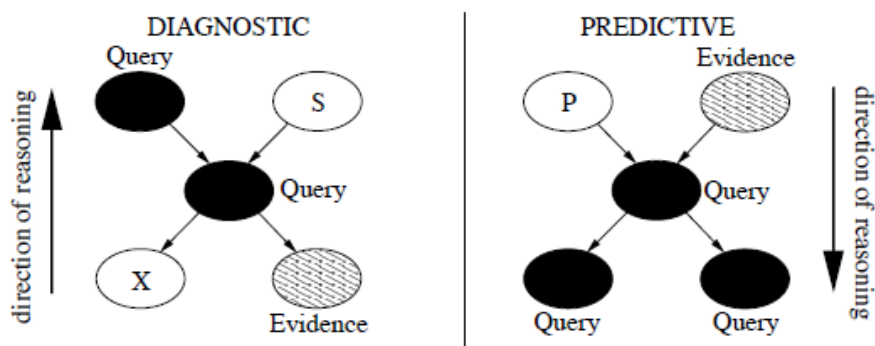


Figura 35. Direcciones de razonamiento [45]

B.4.1. Algoritmo EM

Para entrenar una red Bayesiana con datos incompletos, se utiliza el algoritmo EM (*Expectation Maximization*) introducido en 0, que busca iterativamente encontrar un estimador de máxima verosimilitud para red con los datos disponibles, es decir, busca encontrar los parámetros

más probables que expliquen los datos disponibles. Sea D el set de datos observables (Y) e incompletos (X), y θ los parámetros de la red Bayesiana. Se quiere maximizar la probabilidad de que el set de datos D sea explicado por los parámetros θ , dada una estructura. Por conveniencia, se utiliza el logaritmo de la verosimilitud [52]:

$$L(\theta) = \log(P(D|\theta)). \quad (33)$$

En el caso en que D sea conocido en su totalidad, la solución es trivial ya que la verosimilitud puede ser descompuesta en multiplicaciones condicionales de los nodos a sus padres, y se encuentra con el algoritmo ML (*Maximum Likelihood*). Cuando existen datos incompletos, no se puede realizar esta descomposición debido a que pueden existir asociaciones entre parámetros del modelo no reflejadas. Como no se tiene un valor exacto, se calcula el valor esperado de la función y se maximiza este valor. Esto se puede ver reflejado en los dos pasos que componen el algoritmo, en que se entrega una estimación inicial θ^0 de los parámetros:

- **Paso E:** Calcula el valor esperado de la función $L(\theta)$, dado los parámetros θ^k .
- **Paso M:** Calcula el θ^{k+1} que maximiza el valor esperado anterior.

Estos pasos se repiten hasta que no hay un aumento significativo del valor de la función de verosimilitud.

B.5. Modelo difuso tipo Mamdani

Un modelo difuso tipo Mamdani se conforma por reglas lingüísticas del tipo:

$$R_i: \text{si } x \text{ es } A_i \text{ y } \dots \text{ y es } B_i, \text{ entonces } z \text{ es } C_i,$$

en que los conjuntos A_i , B_i y C_i representan conceptos lingüísticos, como “alto” o “mucho”. Las variables x e y se denominan *antecedentes*, mientras que z es el *consecuente* [53]. En la Figura 36 se muestra un esquema básico para un sistema difuso lingüístico.

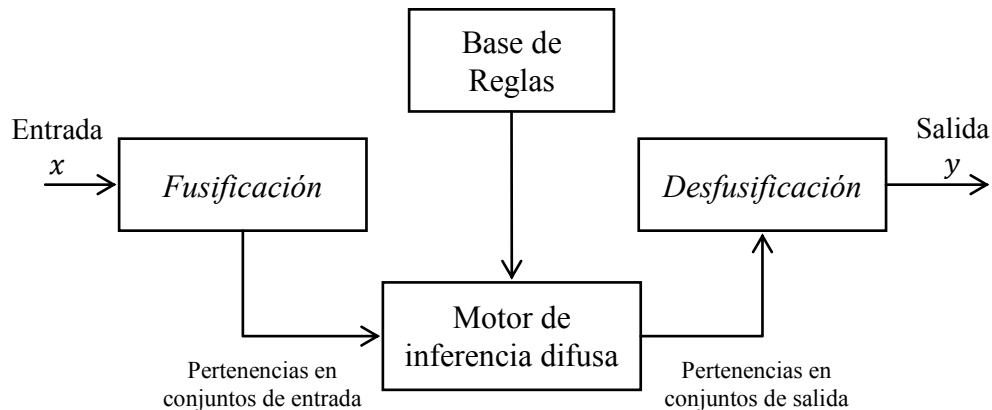


Figura 36. Esquema básico de un sistema difuso [54]

La *fusificación* de las entradas se logra mediante la asignación de grados de pertenencia de los antecedentes a los conjuntos difusos de entrada. El grado de pertenencia de la entrada x al

conjunto A_i se denota $\mu_{A_i}(x)$. Teniendo las pertenencias a los conjuntos de entrada, se realiza el proceso de inferencia, que consiste en derivar un conjunto difuso de salida dadas las reglas y entradas. Para este proceso de inferencia, se sigue el proceso *max-min*:

1. Para cada regla R_i , se calcula su grado de cumplimiento β_i dados los antecedentes, como:

$$\beta_i = \mu_{A_{i1}}(x_1) \wedge \dots \wedge \mu_{A_{ip}}(x_p), \quad (34)$$

donde el operador \wedge corresponde a la *t-norma* que puede corresponder al mínimo o al producto de los grados de pertenencia.

2. Para cada regla se deriva su conjunto difuso B'_i de salida, dadas las entradas, expresado por su grado de pertenencia:

$$\mu_{B'_i}(y) = \beta_i \wedge \mu_{B_i}(y), \quad \forall y \in Y. \quad (35)$$

3. El conjunto difuso agregado de salida se obtiene calculando la unión de todos los conjuntos difusos B'_i de cada regla o, equivalentemente, el máximo de los grados de pertenencia para todo el rango de salida Y :

$$B = \bigcup_i B'_i \Leftrightarrow \mu_B(y) = \max_i \mu_{B'_i}(y), \quad \forall y \in Y. \quad (36)$$

Teniendo el conjunto difuso B , se necesita obtener un valor único de salida, proceso llevado a cabo por la *desfusificación*. Los métodos de más utilizados para este proceso consisten en el cálculo del centro de gravedad del conjunto B proyectado sobre el rango de la salida, y en el cálculo la media del rango del máximo grado de pertenencia. En la Figura 37 se pueden ver ambos métodos gráficamente.




Figura 37. Métodos de defusificación [53]

C. Anexo: Resultados

En este anexo se muestran los resultados de la implementación, mostrando la estructura obtenida para los modelos tipo Mamdani y los resultados completos de las pruebas realizadas sobre el EMS.

C.1. Modelos tipo Mamdani

Para el modelo tipo Mamdani obtenido en el escenario 1, la base de reglas derivadas es:

R_1 :	Si	hora	es	Mañana	y	color	es	Verde	entonces	ρ_L	es	Aumenta Poco
R_2 :	Si	hora	es	Tarde	y	color	es	Verde	entonces	ρ_L	es	Aumenta Poco
R_3 :	Si	hora	es	Noche	y	color	es	Verde	entonces	ρ_L	es	Aumenta Mucho
R_4 :	Si	hora	es	Mañana	y	color	es	Amarillo	entonces	ρ_L	es	Mantiene
R_5 :	Si	hora	es	Tarde	y	color	es	Amarillo	entonces	ρ_L	es	Mantiene
R_6 :	Si	hora	es	Noche	y	color	es	Amarillo	entonces	ρ_L	es	Mantiene
R_7 :	Si	hora	es	Mañana	y	color	es	Rojo	entonces	ρ_L	es	Baja Mucho
R_8 :	Si	hora	es	Tarde	y	color	es	Rojo	entonces	ρ_L	es	Baja Poco
R_9 :	Si	hora	es	Noche	y	color	es	Rojo	entonces	ρ_L	es	Baja Poco

Para el modelo tipo Mamdani obtenido en el escenario 2, la base de reglas derivadas es:

R_1 :	Si	hora	es	Mañana	y	color	es	Verde	entonces	ρ_L	es	Aumenta Poco
R_2 :	Si	hora	es	Tarde 1	y	color	es	Verde	entonces	ρ_L	es	Aumenta Mucho
R_3 :	Si	hora	es	Tarde 2	y	color	es	Verde	entonces	ρ_L	es	Aumenta Poco
R_4 :	Si	hora	es	Tarde 3	y	color	es	Verde	entonces	ρ_L	es	Aumenta Poco
R_5 :	Si	hora	es	Tarde 4	y	color	es	Verde	entonces	ρ_L	es	Aumenta Mucho
R_6 :	Si	hora	es	Noche	y	color	es	Verde	entonces	ρ_L	es	Aumenta Poco
R_7 :	Si	hora	es	Mañana	y	color	es	Amarillo	entonces	ρ_L	es	Baja Poco
R_8 :	Si	hora	es	Tarde 1	y	color	es	Amarillo	entonces	ρ_L	es	Mantiene
R_9 :	Si	hora	es	Tarde 2	y	color	es	Amarillo	entonces	ρ_L	es	Aumenta Poco
R_{10} :	Si	hora	es	Tarde 3	y	color	es	Amarillo	entonces	ρ_L	es	Mantiene
R_{11} :	Si	hora	es	Tarde 4	y	color	es	Amarillo	entonces	ρ_L	es	Mantiene
R_{12} :	Si	hora	es	Noche	y	color	es	Amarillo	entonces	ρ_L	es	Mantiene
R_{13} :	Si	hora	es	Mañana	y	color	es	Rojo	entonces	ρ_L	es	Baja Poco
R_{14} :	Si	hora	es	Tarde 1	y	color	es	Rojo	entonces	ρ_L	es	Baja Mucho
R_{15} :	Si	hora	es	Tarde 2	y	color	es	Rojo	entonces	ρ_L	es	Baja Mucho
R_{16} :	Si	hora	es	Tarde 3	y	color	es	Rojo	entonces	ρ_L	es	Baja Mucho
R_{17} :	Si	hora	es	Tarde 4	y	color	es	Rojo	entonces	ρ_L	es	Baja Poco
R_{18} :	Si	hora	es	Noche	y	color	es	Verde	entonces	ρ_L	es	Baja Poco

En la Figura 38 y Figura 39 se puede apreciar gráficamente los conjuntos difusos tanto para la hora como para el factor de respuesta obtenidos para ambos escenarios considerados. No se grafican los conjuntos de color del semáforo por ser triviales y estar graficados en la Figura 7.

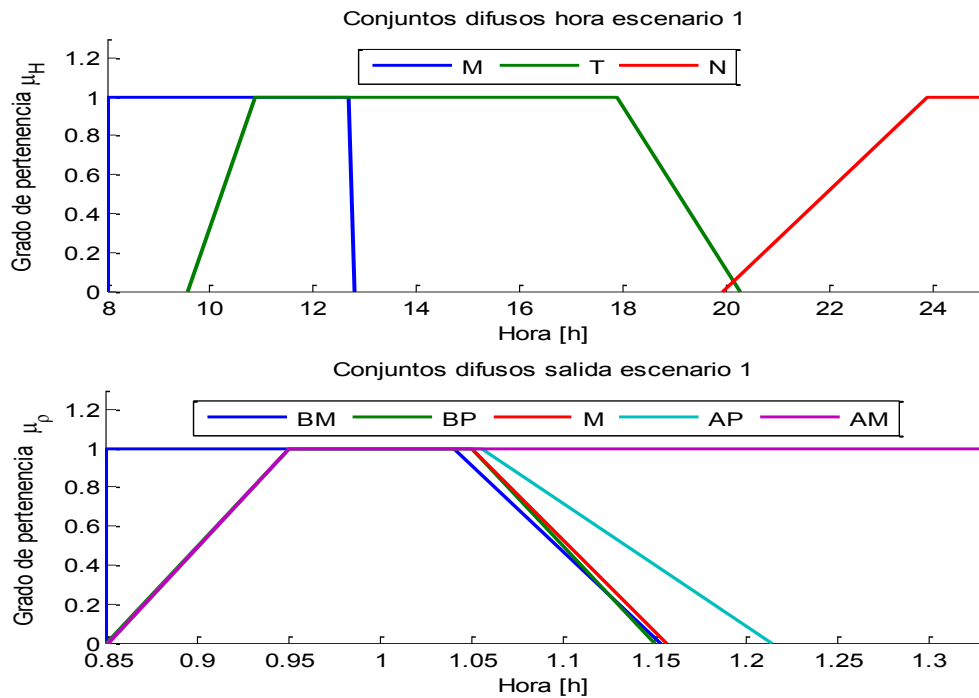


Figura 38. Conjuntos difusos hora y factor de respuesta para escenario 1




Figura 39. Conjuntos difusos hora y factor de respuesta para escenario 2

C.2. Pruebas sobre el EMS

En las siguientes figuras, se muestran ejemplificaciones tanto los factores de desplazamiento deseados S_L , como la operación de las distintas unidades de la micro-red junto con la demanda, para los dos escenarios considerados.




Figura 40. Factores S_L para un día sin potencia eólica




Figura 41. Operación de la micro-red en el escenario 1 con potencia eólica

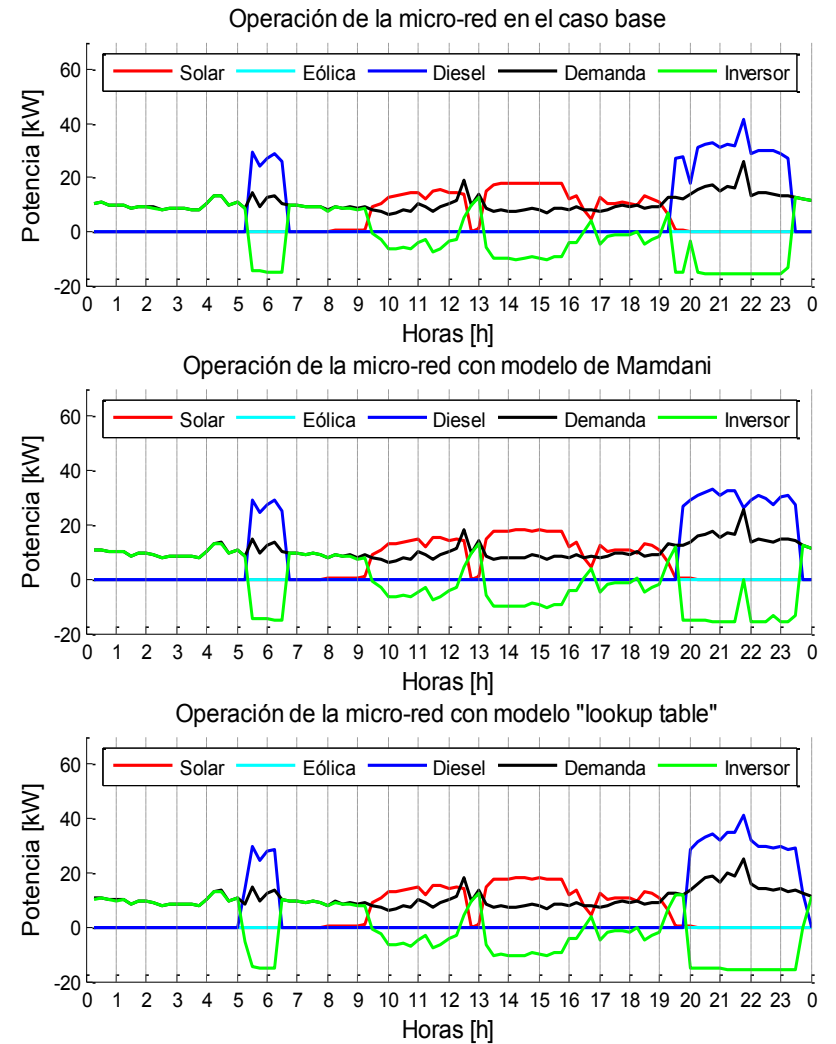


Figura 42. Operación de la micro-red en el escenario 1 sin potencia eólica




Figura 43. Operación de la micro-red en el escenario 2 sin potencia eólica