



UNIVERSIDAD DE CHILE

FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS

DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

**PLANIFICACIÓN DE MICRO-REDES PARA COMUNIDADES RURALES
CON CARACTERIZACIÓN DE INCERTIDUMBRE DE LOS RECURSOS
RENOVABLES Y DEMANDA ELÉCTRICA**

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

RAÚL ADOLFO MORALES CARO

PROFESOR GUÍA:
DORIS SÁEZ HUEICHAPAN

PROFESOR CO-GUÍA:
ROBERTO CÁRDENAS DOBSON

MIEMBROS DE LA COMISIÓN:
CARLOS MUÑOZ POBLETE
PATRICIO MENDOZA ARAYA

SANTIAGO DE CHILE
2017

RESUMEN DE TESIS PARA OPTAR
AL GRADO DE MAGÍSTER EN CIENCIAS DE LA
INGENIERÍA, MENCIÓN ELÉCTRICA
POR : RAÚL MORALES C.
FECHA : 13/03/2017
PROF. GUÍA : DORIS SÁEZ H.
PROF. CO-GUÍA : ROBERTO CÁRDENAS D.

“Diseño de Micro-redes para comunidades rurales con caracterización de incertidumbre de los recursos renovables y demanda eléctrica”

Las micro-redes son soluciones sustentables para la electrificación de zonas rurales que pueden hacer uso de sus recursos renovables. En este estudio, se propone un nuevo método para la planificación de micro-redes que incluye explícitamente el efecto de la incertidumbre de variables críticas que definen el diseño del sistema, como lo son las fuentes renovables y la demanda eléctrica. Se propone la utilización modelos difusos de T&S y modelos de intervalos basados en el método de la covarianza, ya que los primeros permiten caracterizar las no-linealidades del fenómeno a modelar, mientras que los segundos pueden representar sistemáticamente las incertidumbres asociadas a dichas variables críticas con un cierto nivel de confianza.

Para el diseño de cualquier sistema eléctrico se requiere identificar la dimensión y comportamiento de carga a la cual se desea abastecer a través de su registro continuo y prolongado, lo cual no siempre es posible, especialmente si se trata de localidades aisladas o de difícil acceso. Para solucionar esto, se implementa un simulador de carga basado en Cadenas de Markov, obtenido a partir de la agrupación previa de hogares en función de su información socio-demográfica empleando el algoritmo de redes neuronales “*Self-Organizing Map*”.

Basado en modelos de intervalos, se obtienen un conjunto de escenarios posibles, en donde se resuelve el problema de optimización de planificación de la micro-red, obteniendo la topología del sistema y el dimensionamiento de cada una de sus unidades. Los resultados obtenidos en este proceso son la base para el estudio de factibilidad y de diseño de un proyecto de micro-red.

La metodología propuesta es aplicada para la planificación de una micro-red conectada a la red principal, basada en fuentes solar y eólica, en la comunidad rural Mapuche de José Painecura Hueñalihuen, IX Región de la Araucanía, Chile. En este caso de estudio, se determina que la modelación lineal es suficiente para caracterizar el comportamiento de la velocidad del viento y de la radiación solar, mientras que se requiere de la identificación de un modelo difuso para representar la no-linealidad del comportamiento de la demanda eléctrica. Por otro lado, a través de la identificación de modelos de intervalos, se obtiene que la velocidad del viento presenta una mayor incertidumbre que la radiación solar y la demanda eléctrica. Por lo tanto, el recurso eólico es la variable que mayor influencia tiene en la diferenciación de los distintos escenarios posibles. En función de las características locales y técnicas de cada unidad considerada, junto con los costos estimados y considerando un escenario conversador, se obtiene que el diseño final la micro-red es principalmente compuesta por tecnología fotovoltaica.

Dedicatoria

*A mi padre Raúl y a mi hermano Felipe
quienes han sido un apoyo incondicional
durante la realización de esta tesis
y durante toda mi vida.*

Agradecimientos

En este espacio quiero expresar mis más sinceros agradecimientos a todos quienes han sido un aporte directo o indirecto al desarrollo de este trabajo de tesis y en mi periodo estudio en el programa de Magíster.

En primer lugar, agradezco a mi familia, partiendo por mi padre, quien ha sido el pilar fundamental y un apoyo incondicional en todas mis decisiones, incluyendo las más difíciles, para llegar a ser el profesional que soy; y a mi hermano, que prácticamente ha sido un amigo más en mi vida.

A mi profesora guía, Doris Sáez Hueichapan, quien me dio la oportunidad y todas las facilidades para regresar a la Universidad y trabajar en un proyecto desafiante con gran impacto social. Sin duda, este ha sido un periodo en que he aprendido demasiado y se lo debo principalmente a ella. Obviamente mi agradecimiento va también a mis compañeros de proyecto, la Caro, el Víctor y Enrique, con quienes hicimos un excelente equipo de trabajo y buenos amigos, cuyos aportes fueron fundamentales para llevar a buen puerto esta iniciativa. Agradezco al proyecto FONDEF ID14I10063, donde se enmarca el presente trabajo; al Instituto Sistemas Complejos de Ingeniería ICM: P-05-004-F; y a Solar Energy Research Center (SERC) CONICYT: FBO16, CONICYT/FONDAP/15110019 por su respaldo.

A la comunidad Mapuche Lafkenche José Painecura Hueñalihuen, pues sin el apoyo de ellos y su buena disposición, este trabajo hubiese sido muy difícil o probablemente imposible de realizar con el nivel de detalle aquí presentado. Mis especiales agradecimientos a Don Florindo, lonko de la comunidad, a su esposa Ana, a Juan de Dios, Erme y Myriam Nancy, que siempre me recibieron como si fuera parte de la familia cada vez que iba a terreno.

El ambiente universitario que otorga esta Universidad es un espacio donde, si se tiene algo suerte, es posible conocer personas de una inmensa calidad humana. En mi regreso a esta Facultad no fue la excepción. Sumado a mis compañeros de proyecto ya mencionados, mis agradecimientos van también a mis compañeros de laboratorio y controlistas innatos: Toño, Pato, Tomi, Leo, Cata (la robot), Cristian y Bachi, quienes me hicieron parte de un gran grupo de amigos, siempre presentes cuando necesitaba de su ayuda técnica, discutir algún tema de la vida o para compartir una buena cerveza. A mis compañeros extranjeros Yanira, compañera en mis cursos y una gran amiga; y Luis, ambos muy lindas personas y un ejemplo a seguir.

Por último, agradezco a mis amigos de infancia Chiki y Mario, pues su constante preocupación, empatía, y confianza en mi trabajo durante este proceso es reflejo de una amistad auténtica que espero no se pierda nunca.

A todos quienes depositaron su confianza en mí, fueron un apoyo efectivo o simplemente me desearon lo mejor en este proceso, con todos ustedes deseo compartir este logro.

Tabla de contenido

Capítulo 1. Introducción.	1
1.1. Motivación.	1
1.2. Objetivos.	2
1.2.1. Objetivo general.	2
1.2.2. Objetivos específicos.	2
1.3. Hipótesis.	2
1.4. Metodología.	3
1.5. Estructura de trabajo.	4
Capítulo 2. Antecedentes y Procedimientos.	6
2.1. Micro-redes.	6
2.1.1. Definición.	6
2.1.2. Tipos de micro-redes.	7
2.1.3. Planificación de micro-redes.	9
2.1.4. Caracterización de incertidumbre de los recursos renovables y carga.	11
2.2. Modelamiento de sistemas.	12
2.2.1. Modelación lineal.	13
2.2.2. Modelación difusa de Takagi & Sugeno.	14
2.3. Identificación de sistemas.	18
2.3.1. Obtención de datos de identificación.	20
2.3.2. Selección de variables relevantes.	21
2.3.3. Optimización de la estructura.	23
2.3.4. Identificación de los parámetros de las premisas.	24
2.3.5. Identificación de los parámetros de las consecuencias.	26
2.3.6. Análisis de estabilidad.	28
2.4. Estabilidad de Modelos Difusos.	28
2.4.1. Estabilidad según Lyapunov.	29
2.4.2. Estabilidad de modelos difusos discretos.	29
2.4.3. Metodología para análisis de estabilidad de modelos difusos.	30
2.5. Modelos de intervalos.	32
2.5.1. Generalidades.	32
2.5.2. Método de la covarianza.	33
2.5.3. Índices de evaluación de intervalos.	36
2.6. Self-Organizing Map.	37
2.6.1. Definición.	37
2.6.2. Proceso de entrenamiento.	38
2.7. Generación de perfiles aleatorios.	40
2.7.1. Cadenas de Markov.	40
2.7.2. Metodología para generación de perfiles.	42
2.8. Discusión.	47
Capítulo 3. Caracterización de los recursos renovables y demanda eléctrica.	48

3.1. Caso de Estudio: Comunidad de José Paineicura Hueñalihuen.	48
3.2. Condiciones climáticas y geográficas.	49
3.3. Recursos energéticos.	52
3.3.1. Recurso eólico.	53
3.3.2. Recurso solar.	55
3.4. Modelo del recurso eólico.	56
3.4.1. Modelación lineal y modelación difusa de Takagi-Sugeno.	56
3.4.2. Inclusión de incertidumbre mediante intervalo de confianza.	60
3.5. Modelo del recurso solar.	62
3.5.1. Modelación lineal y modelación difusa de Takagi-Sugeno.	62
3.5.2. Inclusión de incertidumbre mediante intervalo de confianza.	67
3.6. Estimación y modelo de demanda eléctrica.	69
3.6.1. Clasificación de hogares.	69
3.6.2. Variabilidad en perfiles de consumo.	74
3.6.3. Perfil de demanda comunitaria.	78
3.6.4. Modelación lineal y modelación difusa de Takagi-Sugeno.	82
3.6.5. Inclusión de incertidumbre mediante intervalo de confianza.	85
3.7. Discusión.	87
Capítulo 4. Diseño de la micro-red.	89
4.1. Planificación de micro-redes.	89
4.1.1. Metodología propuesta.	89
4.1.2. Software de dimensionamiento de micro-redes: HOMER.	92
4.2. Condiciones y parámetros de diseño.	96
4.2.1. Consideraciones generales.	96
4.2.2. Características técnicas y económicas de las tecnologías de generación.	99
4.2.3. Demanda adicional por desarrollo productivo.	104
4.3. Resultados.	110
4.3.1. Resultados de optimización.	110
4.3.2. Resultados de análisis de sensibilidad.	114
4.3.3. Operación del sistema.	115
4.4. Discusión.	117
Capítulo 5. Conclusiones y trabajo futuro.	118
5.1. Conclusiones generales.	118
5.2. Líneas de investigación futuras.	119
5.3. Publicaciones generadas.	119
Bibliografía.	120
Anexos.	130
Anexo A. Algoritmos.	130
A.1. Algoritmo genético.	130
A.2. Algoritmo <i>k-means</i> .	131
Anexo B. Resultados en identificación de modelos.	132

B.1. Resultados en análisis de estabilidad.	132
B.2. Parámetros de las premisas de los modelos identificados.	134
Anexo C. Resultados en simulación de demanda eléctrica.	135
C.1. Distribución de frecuencias por clase.	135
C.2. Índices estadísticos por clase.	137
C.3. Parámetros de las cadenas de Markov.	139
Anexo D. Dimensionamiento de sistema de riego.	142
D.1. Serie de suelo.	142
D.2. Requerimientos de riego.	143

Índice de figuras

Figura 1.1: Estructura de la metodología de trabajo.	3
Figura 2.1: Arquitectura de una micro-red.	7
Figura 2.2: μ grid en Sendai, Japón [22].	8
Figura 2.3: Mgrid en Borrego Springs, California [23].	8
Figura 2.4: Rgrid en Huatacondo, Chile [24].	9
Figura 2.5: Aproximación lineal con modelo de T&S.	17
Figura 2.6: Proceso de identificación de sistemas.	19
Figura 2.7: Proyección de 3 clusters en 2 variables de entrada [67].	26
Figura 2.8: Metodología para el análisis de estabilidad de modelos difusos de T&S [55].	31
Figura 2.9: Diagrama de entradas y salidas de SOM.	38
Figura 2.10: Proceso de entrenamiento SOM.	39
Figura 2.11: SOM entrenado.	40
Figura 2.12: Procedimiento para generación de perfiles aleatorios.	42
Figura 2.13: Esquema de generación de datos con cadenas de Markov [88].	46
Figura 3.1: Ubicación geográfica de la comunidad de José Paineicura Hueñalihuen [89].	48
Figura 3.2: Diagrama climático - Estación meteorológica de Puerto Saavedra [92].	50
Figura 3.3: Regiones del mundo con clima templado lluvioso [92].	51
Figura 3.4: Condiciones geográficas de la comunidad de José Paineicura Hueñalihuen. (a) Mapa de alturas; (b) Mapa de pendientes.	52
Figura 3.5: Potencial eólico en José Paineicura Hueñalihuen.	54
Figura 3.6: Velocidad promedio del viento en José Paineicura Hueñalihuen.	54
Figura 3.7: Potencial solar en José Paineicura Hueñalihuen.	55
Figura 3.8: Insolación diaria en José Paineicura Huenalihuen.	56
Figura 3.9: Funciones de pertenencia del recurso eólico.	58
Figura 3.10: Desempeño de los modelos del recurso eólico a 24 pasos.	59
Figura 3.11: Intervalos lineales del recurso eólico a 1 paso.	60
Figura 3.12: Intervalos lineales del recurso eólico a 24 pasos.	61
Figura 3.13: Funciones de pertenencia del recurso solar.	64
Figura 3.14: Desempeño de los modelos del recurso solar a 24 pasos.	66
Figura 3.15: Intervalos lineales del recurso solar a 1 paso.	67
Figura 3.16: Intervalos lineales del recurso solar a 24 pasos.	68
Figura 3.17: Agrupación de hogares obtenidas a través del algoritmo SOM.	71
Figura 3.18: Perfiles de carga promedio por clase.	73
Figura 3.19: Diferenciación del perfil de carga promedio de la clase Pangí para distintos días de la semana.	74
Figura 3.20: Demanda eléctrica por clase en un día tipo.	76
Figura 3.21: Demanda eléctrica promedio por clase.	77
Figura 3.22: Diferenciación del perfil de carga promedio de la Escuela para distintos días de la semana.	79
Figura 3.23: Consumo promedio mensual.	79
Figura 3.24: Perfil de carga de la comunidad de 4 días de simulación.	80
Figura 3.25: Perfil de carga promedio de la comunidad.	81
Figura 3.26: Perfil de carga de la comunidad de un año de simulación.	81
Figura 3.27: Funciones de pertenencia de la demanda eléctrica.	83
Figura 3.28: Desempeño de los modelos de demanda eléctrica a 24 pasos.	84
Figura 3.29: Intervalos lineales de la demanda eléctrica a 1 paso.	86
Figura 3.30: Intervalos lineales de la demanda eléctrica a 24 pasos.	86
Figura 4.1: Diagrama del modelo de batería cinética.	95
Figura 4.2: Diagrama esquemático de la micro-red.	97
Figura 4.3: Temperatura promedio en Hueñalihuen.	98
Figura 4.4: Consumo histórico bimestral promedio.	98
Figura 4.5: Confiabilidad de la red principal.	99

Figura 4.6: Curva de potencia de aerogeneradores de 3.5 [kW] y 10 [kW].	100
Figura 4.7: Precios mayoristas históricos del diésel.	104
Figura 4.8: Evapotranspiración potencial en la localidad de Nehuentue.	106
Figura 4.9: Precipitación en la estación de Puerto Saavedra.	108
Figura 4.10: Demanda energética por desarrollo productivo.	109
Figura 4.11: Producción mensual promedio de energía.	113
Figura 4.12: Resumen de costos del proyecto.	114
Figura 4.13: Producción anual del sistema fotovoltaico.	116
Figura 4.14: Producción anual del generador diésel.	116
Figura 4.15: Compras anuales desde la red.	117
Figura 4.16: Ventas anuales hacia la red.	117
Figura A.1: Histogramas de variables por clase.	137
Figura A.2: Series de suelo - Región de la Araucanía [131].	142

Índice de tablas

Tabla 3.1: Medidas de error de los modelos del recurso eólico a 1 paso.	59
Tabla 3.2: Medidas de error de los modelos del recurso eólico a 24 pasos.	59
Tabla 3.3: Desempeño de los modelos de intervalos lineales del recurso eólico.	61
Tabla 3.4: Medidas de error de los modelos del recurso solar a 1 paso.	66
Tabla 3.5: Medidas de error de los modelos del recurso solar a 24 pasos.	66
Tabla 3.6: Desempeño de los modelos de intervalos lineales del recurso solar.	68
Tabla 3.7: Variables relevantes para la caracterización de consumo por hogar.	70
Tabla 3.8: Resumen de clasificación de hogares.	72
Tabla 3.9: Registro de datos por clase.	73
Tabla 3.10: Características de grupo de datos de consumo por clase.	75
Tabla 3.11: Medida de error de la demanda eléctrica simulada por clase.	77
Tabla 3.12: Medidas de error de los modelos de demanda eléctrica a 1 paso.	85
Tabla 3.13: Medidas de error de los modelos de demanda eléctrica a 24 pasos.	85
Tabla 3.14: Desempeño de los modelos de intervalos lineales de la demanda eléctrica.	87
Tabla 4.1: Requerimientos de cultivo.	105
Tabla 4.2: Coeficiente de cultivo de la papa, trigo y avena.	106
Tabla 4.3: Propiedades del suelo de la asociación Nahuelbuta.	107
Tabla 4.4: Resultados del sistema de riego para desarrollo productivo.	109
Tabla 4.5: Diseño de micro-redes bajo distintos escenarios.	111
Tabla 4.6: Costos asociados a micro-redes bajo distintos escenarios.	111
Tabla 4.7: Resultados de operación de micro-redes bajo distintos escenarios.	112
Tabla 4.8: Sensibilidad en los costos asociados a la micro-red.	115
Tabla A.1: Norma de los polos en modelos del recurso eólico.	132
Tabla A.2: Norma de los polos en modelos del recurso solar.	133
Tabla A.3: Norma de los polos en modelos de demanda eléctrica.	133
Tabla A.4: Parámetros de las premisas del modelo difuso de T&S del recurso eólico.	134
Tabla A.5: Parámetros de las premisas del modelo difuso de T&S del recurso solar.	134
Tabla A.6: Parámetros de las premisas del modelo difuso de T&S de la demanda eléctrica	135
Tabla A.7: Índices estadísticos de la clase Nawel.	137
Tabla A.8: Índices estadísticos de la clase Kura.	138
Tabla A.9: Índices estadísticos de la clase Lafken.	138
Tabla A.10: Índices estadísticos de la clase Guru.	138
Tabla A.11: Índices estadísticos de la clase Pangi.	139
Tabla A.12: Requerimientos de riego del cultivo de papa de primera temporada.	144
Tabla A.13: Requerimientos de riego del cultivo de papa de segunda temporada.	145
Tabla A.14: Requerimientos de riego del cultivo de trigo y avena.	146

Acrónimos y Siglas

AIC : (*Akaike's Information Criterion*) Índice de Información de Akaike

AR : Auto-Regresivo

CoE : (*Cost of Energy*) Costo de la Energía

CP : (*Confidence Probability*) Probabilidad de Confianza

CPN : Costo Presente Neto

DER : (*Distributed Energy Resources*) Recursos Energéticos Distribuidos

EMS : (*Energy Management System*) Sistema de Gestión de Energía

ERNC : Energías Renovables No Convencionales

MAE : (*Mean Absolute Error*) Error Medio Absoluto

MF : (*Membership Function*) Función de Pertenencia

MTE : Matriz de Transición de Estados

NAW : (*Normalized Average Width*) Ancho Promedio Normalizado

O&M : Operación y Mantenimiento

RMSE : (*Root Mean Square Error*) Error Cuadrático Medio

SEP : Sistema Eléctrico de Potencia

SIG : Sistema de Información Geográfica

SOM : (*Self-Organizing Map*) Mapa Auto-Organizado

T&S : Takagi & Sugeno

Capítulo 1. Introducción.

1.1. Motivación.

El acceso a la electricidad en zonas rurales se constituye como un factor que incide sobre desarrollo local [1], provocando beneficios directos sobre el territorio, como reducción de la pobreza, la reducción de las migraciones hacia la ciudad, el fomento al desarrollo productivo, y el mejoramiento del acceso a los servicios básicos, como la salud y la educación [2], [3]. En Latinoamérica, los gobiernos han contribuido a mejorar los niveles de suministro de energía eléctrica en zonas aisladas a través de programas de electrificación nacional y regional [4]. Sin embargo, la mayoría de estos proyectos son extensiones de la red eléctrica convencional [5] que implica altos costos de implementación y operación, e importantes dificultades técnicas [6]. Por otra parte, en el caso de comunidades conformada por grupos étnicos minoritarios, se debe tomar una consideración especial para proteger sus características particulares, para hacer posible la implementación de un proyecto que esté de acuerdo con sus creencias, conocimientos y prácticas y sobretodo, para conseguir su gestión sostenible y colectiva de sus recursos naturales.

Bajo este escenario, el uso de Energías Renovables No Convencionales (ERNC), como fuente principal de abastecimiento energético, se presenta como una solución energética atractiva para zonas aisladas rurales [7]. Esto debido a que sus costos económicos en la etapa de operación pueden ser inferiores a otros proyectos de electrificación tradicionales. Además de esto, permite el uso de los recursos renovables propios del sector, con bajo impacto ambiental y que contribuye a la sustentabilidad del territorio [3], [8]. Estas tecnologías, en conjunto a otros pequeños medios de generación, cargas y sistemas de almacenamiento de energía operando como un solo sistema controlable de baja tensión componen una micro-red [9]. A nivel internacional, existe una amplia experiencia sobre instalación de micro-redes a sectores urbanos, como es el caso en Dinamarca, Países Bajos, Estados Unidos, Japón, Canadá y España [10]; y en zonas rurales de Ecuador, Sudáfrica, Marruecos y Bangladesh [11]. También hay casos especiales de micro-redes en zonas insulares de Grecia, Ecuador y México [10], [12].

La motivación en el presente trabajo consiste en aportar al estudio la factibilidad de la implementación de una micro-red en una comunidad de origen étnico de Chile identificado con la cultura Mapuche, pueblo que representa el 84.4% del total de pueblos indígenas del país [13], que se rige por una cosmovisión que sitúa al hombre como un integrante más de su entorno natural, y donde predomina la comunidad por sobre el individuo [14]. La planificación de una micro-red basada en energías renovables en una comunidad Mapuche aislada, se justifica debido a que constituye un sistema que se encuentra vinculado y en concordancia con su cosmovisión, hecho que se ha podido confirmar mediante experiencias en terreno en dos comunidades de la Región de la Araucanía.

1.2. Objetivos.

1.2.1. Objetivo general.

Diseñar una metodología de planificación de micro-redes para comunidades rurales aisladas, mediante modelos de intervalos difusos que consideren la caracterización de incertidumbre asociada al recurso solar, recurso eólico y la estimación de demanda energética a largo plazo.

1.2.2. Objetivos específicos.

Para alcanzar el objetivo general planteado, se abordan los siguientes objetivos específicos:

- Generar un perfil de consumo energético estimado, cuando se carece de su registro histórico, que permita dimensionar las unidades de generación de un proyecto de electrificación.
- Diseñar y comparar distintos modelos de estimación y predicción de radiación solar, velocidad del viento y demanda eléctrica. Posteriormente, emplear los mejores modelos obtenidos para el desarrollo de intervalos de confianza que representen la incertidumbre propia de los recursos renovables y demanda en estudio.
- Diseñar un método de planificación y dimensionamiento de unidades de micro-redes considerando intervalos derivados de los recursos renovables y demanda eléctrica.
- Determinar la factibilidad técnica y económica de un proyecto de implementación de micro-red en la comunidad Mapuche José Painecura Hueñalihuen.

1.3. Hipótesis.

Para la realización del presente trabajo de investigación se han considerado las siguientes hipótesis:

- Es posible caracterizar el comportamiento la radiación solar global, la velocidad del viento y demanda eléctrica de la comunidad mediante modelos lineales y difusos; así como establecer intervalos a través del método de la covarianza que permitirán caracterizar correctamente la incertidumbre de dichas variables y generar distintos escenarios de operación para una micro-red.
- Mediante registro parcial de demanda eléctrica de algunas viviendas representativas de la comunidad en estudio, en conjunto con la información socio-demográfica recopilada a través de encuestas, es posible obtener un perfil de consumo energético simulado que identifique el comportamiento global de la comunidad. Para esto, una cadena de Markov de primer orden es suficiente para la generación de datos representativos.

- Durante el horizonte de evaluación, el comportamiento y tendencia de los recursos renovables solar y eólico, así como la demanda eléctrica de la comunidad se mantienen dentro de los valores esperados dada por las mediciones obtenidas, considerando en esta última un aumento constante por concepto de crecimiento vegetativo y mayor demanda de equipos eléctricos.

1.4. Metodología.

La metodología de trabajo propuesta para el siguiente trabajo se muestra a continuación en la Figura 1.1.

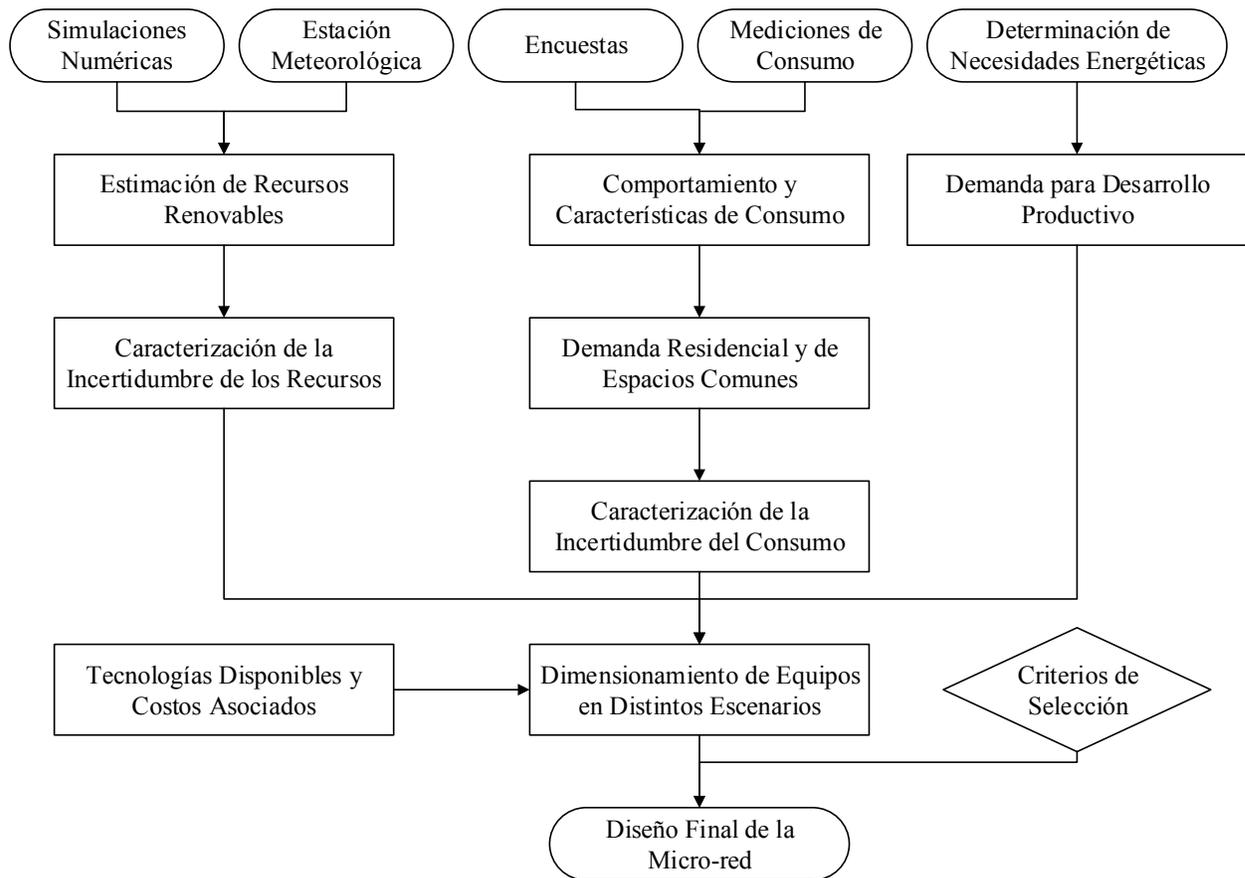


Figura 1.1: Estructura de la metodología de trabajo.

El método propuesto comienza con la determinación del potencial energético solar y eólico disponible en la localidad. Utilizando mediciones registradas in-situ a través de una estación meteorológica y datos simulados extraídos de modelos a mesoescala previamente validados con las mediciones en terreno, se dimensionan y caracterizan los recursos energéticos, para luego determinar sus perfiles horarios en un año completo. Luego, se identifica modelos lineales y difusos de ambos recursos, escogiendo la estructura que presente un mejor desempeño para generar intervalos con un nivel de confianza dado para la caracterización de incertidumbre.

Para la determinación de la demanda energética residencial, en general no se dispondrá del registro continuo del total de hogares que componen una comunidad. Para una estimación adecuada, se recopilan datos socio-demográficos de encuestas de cada hogar para utilizarla en un algoritmo de clasificación que permita agrupar las viviendas de acuerdo a las características que se relacionan con el comportamiento de la demanda. En cada grupo, se escoge una vivienda representativa donde se instala un medidor de consumo, y de esta forma, cada vivienda tendrá asociado un perfil de demanda base. Luego, mediante el método de Cadenas de Markov, se simula un año continuo de consumo residencial variable en función de la data disponible y posteriormente, al igual que en la caracterización del recurso energético, se identifican modelos lineales y difusos, escogiendo el mejor para generar intervalos que caractericen la incertidumbre de la demanda para un nivel de confianza dado. Para el caso de la infraestructura destinada a espacios públicos y comunes, cuyo comportamiento es más determinístico, se mide su consumo promedio y se agrega a la demanda anterior para obtener así el perfil de demanda comunitario.

Por otro lado, las necesidades energéticas asociadas al desarrollo productivo son determinadas mediante la realización de talleres participativos con la comunidad, la que, junto con una primera aproximación de las condiciones territoriales existentes, determina la demanda energética adicional que deberá soportar la micro-red a largo plazo.

Una vez caracterizado el nivel e incertidumbre en la generación y consumo de la comunidad, se realiza el dimensionamiento de los distintos componentes de la micro-red bajo distintos escenarios, considerando las características técnicas de las distintas tecnologías y sus costos asociados a instalación, operación y mantenimiento en un horizonte de evaluación de 20 años. Finalmente, en función de la inversión disponible y del criterio de decisión del inversionista del proyecto (conservador – optimista) se obtiene el diseño final del sistema de micro-red.

1.5. Estructura de trabajo.

La estructura del presente trabajo de tesis está dividida en 5 capítulos, descritos brevemente a continuación.

El Capítulo 1. presenta la introducción y motivación al presente trabajo de tesis, los objetivos generales y específicos que motivan esta investigación, y la descripción de la metodología propuesta para resolver el problema.

El Capítulo 2. se destina a la contextualización del lector en aspectos generales en el ámbito de micro-redes y métodos de planificación. Se describen conceptos y procedimientos de identificación y análisis de estabilidad de sistemas, dando énfasis en las técnicas de modelación difusa, y representación de incertidumbre mediante intervalos. Finalmente, se dan a conocer métodos de simulación de datos basado en algoritmos genéticos y de agrupación.

El Capítulo 3. muestra el caso de estudio y sus principales características. Se obtiene un simulador de demanda basado en la información sociodemográfica y se caracteriza su incertidumbre asociada, junto con la de los recursos solar y eólica a través de modelos de intervalos.

El Capítulo 4. corresponde a la propuesta metodológica para el diseño de la micro-red y la presentación de los resultados obtenidos considerando distintos escenarios. Se analizan los costos involucrados y se simula su operación.

Finalmente, en el Capítulo 5. se presentan las principales conclusiones del trabajo, destacando las contribuciones realizadas y presentando las líneas de investigación futuras.

Capítulo 2. Antecedentes y Procedimientos.

2.1. Micro-redes.

2.1.1. Definición.

Hasta hoy en día, no existe un consenso para la definición para micro-redes [15]. Sin embargo, es posible identificarlos de modo general como sistemas de integrados de energía que contienen cargas y recursos energéticos distribuidos (DERs), que operan de manera coordinada mientras están conectadas y/o aisladas de red de alimentación principal, llamando a esta última operación en “modo isla” [16]–[18], la cual de acuerdo a *General Electric* es la operación más común [19].

CIGRE MicroGrid Working Group en su definición considera que los elementos que componen una micro-red pueden incluir a generadores distribuidos, dispositivos de almacenamiento y/o cargas controlables, dejando como opción su operación controlada y coordinada con la red principal [17]. Por otro lado, *US Department of Energy’s Microgrid Exchange Group* contempla como requisito su operación como única entidad controlable con respecto a la red, además de que sus componentes se encuentren en límites eléctricos claramente definidos [18].

Campbell [20] identifica una micro-red de manera más amplia, definiéndolas como cualquier sistema eléctrico de potencia (SEP) pequeño o local que es independiente de la red eléctrica mayor. Por ejemplo, puede ser un sistema combinado de calor y potencia basada en un motor de combustión de gas natural (que se utiliza para cogeneración de electricidad y agua caliente o vapor usado para enfriar la turbina de gas natural), generadores diésel, energía renovable o celdas de combustible. Una micro-red puede ser usada para servir las necesidades eléctricas de data centers, escuelas, hospitales, industrias, bases militares, o comunidades enteras.

De forma similar, Lasseter [9] define estos sistemas en función de las necesidades especiales que satisface tales como: mejorar la confiabilidad local del servicio, reducir pérdidas del alimentador, respaldar la regulación de tensión local, proporcionar una mayor eficiencia mediante la corrección de caídas de tensión o proporcionar alimentación ininterrumpida, entre otros. Por otro lado, St. John [21] señala que una micro-red es mucho más que un sistema de respaldo de energía, incluso si esta es una de sus funciones básicas para la que fue diseñada. Estos sistemas deben incluir un sistema de control in situ que realice el balance entre generación, almacenamiento y consumo de energía en tiempo real, así como también su interacción con la red.

Las distintas definiciones de un sistema de micro-red difieren principalmente en la capacidad de generación agregada que debe estar contenida en el sistema eléctrico y si debe haber un único o múltiples puntos de conexión con la red principal [15]. No obstante, de acuerdo a las distintas referencias estudiadas, una micro-red debe incluir:

- Combinación de cargas y fuentes de generación de energía interconectadas en el mismo sistema eléctrico.
- Operación en isla y/o conectado a la red.

- Presentación a la red principal como una única unidad controlable.
- Disposición de una mejor calidad y confiabilidad de energía para los usuarios finales.
- Diseño acorde a las necesidades energéticas locales.

Un diagrama simple es presentado en la Figura 2.1 para mostrar gráficamente el concepto de micro-red. En este ejemplo, el sistema se compone de distintas fuentes de generación (renovables), un medio de respaldo a través de un generador diésel, un sistema de almacenamiento mediante baterías y cargas de distintas características, algunas de ellas con la posibilidad de ser programables. El flujo de energía entre los distintos componentes es representado por flechas que indican su dirección y la separación física entre la micro-red y la red principal se denomina Punto de Acoplamiento Común (PCC por sus siglas en inglés).

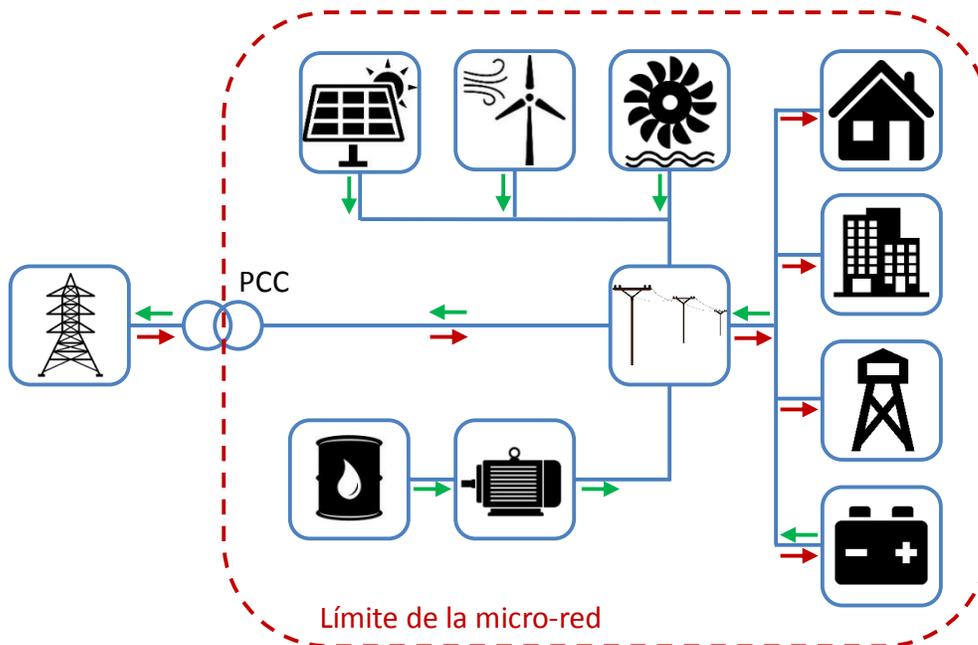


Figura 2.1: Arquitectura de una micro-red.

2.1.2. Tipos de micro-redes.

Microgrids Group at Berkeley Lab [22] ha distinguido cuatro tipos de micro-redes:

1. **Micro-redes verdaderas (μ grids):** Micro-redes auto-gestionadas, por lo general aguas abajo de un único punto de acoplamiento común (PCC). La mayoría de los proyectos de micro-red son de este tipo y son particularmente fáciles de entender, pues se ajustan perfectamente a la tecnología actual y marco regulador. Del mismo modo que un cliente tiene una considerable libertad de acción para la operación de su sistema eléctrico en su lado del medidor, las restricciones técnicas de la normativa vigente aplicadas a una μ grid son menores. Se espera que la masificación de estos sistemas corresponda a este tipo,

siguiendo referentes como *The Sendai Microgrid Project* (Figura 2.2), desarrollado por *New Energy and Industrial Technology Development Organization* (NEDO) en Japón entre el 2005 y 2008. Hasta hoy en día, dicho proyecto sigue siendo totalmente operacional, destacando además su excelente desempeño durante el terremoto y tsunami del 2011, donde fue capaz de abastecer de energía el hospital de *Tohoku Fukushi University* durante el black-out de dos días.



Figura 2.2: μ grid en Sendai, Japón [22].

2. **Micro-redes de servicio público / comunitario o mili-redes (*mgrids*):** Estos sistemas implican un segmento de la red regulada (red de distribución). Si bien, técnicamente no hay diferencias con las μ grid, son fundamentalmente diferentes desde una perspectiva de modelo de regulación y de negocios, ya que incorporan infraestructura de servicios públicos tradicionales. En este caso, la regulación de las utilidades obtenidas es mucho más relevante, pues una *mgrid* debe cumplir con las leyes y normativas vigentes de servicio público. Un ejemplo de estos sistemas es la micro-red de *San Diego Gas and Electric Company's* (SDG&E) en la comunidad residencial de 2800 clientes de Borrego Spring, California (Figura 2.3), donde los activos de distribución son propiedad de la empresa de servicios públicos, mientras que los DERs son propiedad de los clientes.



Figura 2.3: Mgrid en Borrego Springs, California [23].

3. **Micro-redes virtuales (*vgrids*):** Sistemas que cubren DERs en múltiples sitios, pero se coordinan de tal manera que pueden ser vistos desde la red como una sola entidad controlada. No existen muchos sistemas de este tipo, aunque si ha sido propuesto en la literatura. Es necesario recordar que, para ser consistente con la definición de micro-red, el sistema debe ser capaz de operar en modo isla controlado o en múltiples islas coordinadas entre sí.
4. **Sistemas de energía remota (*rgrids*):** Evidentemente no son capaces de funcionar conectado a la red, sin embargo, los sistemas de energía aislados involucran una tecnología similar y están estrechamente relacionados. Por este motivo, desde el punto de vista de investigación, son comúnmente descritos como micro-redes. En esta clasificación se destaca el proyecto desarrollado por la Universidad de Chile para abastecer a la comunidad andina de Huatacondo (Figura 2.4), conformada por 150 habitantes con participación activa en la operación y mantenimiento del sistema.

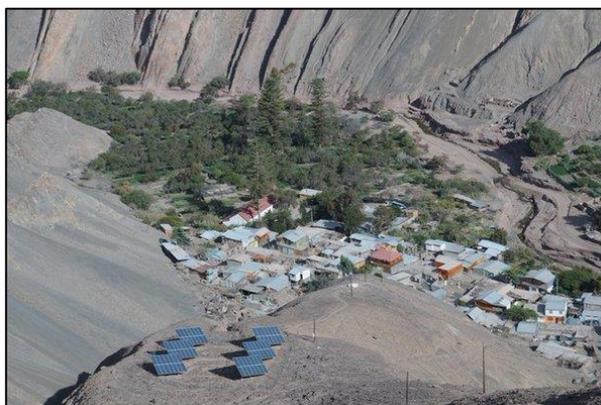


Figura 2.4: Rgrid en Huatacondo, Chile [24].

En función a lo anterior, debido a las diferentes condiciones y características locales, junto con las distintas necesidades que un sistema de micro-red puede abastecer, se determina la importancia de la correcta planificación de estos sistemas energéticos, pues es crítico para su operación eficiente.

2.1.3. Planificación de micro-redes.

En el contexto del presente trabajo, se entenderá por planificación a aquel procedimiento previo a la etapa de operación requerido para establecer una operación óptima factible. En el caso particular de una micro-red, esta operación óptima puede enfocarse en objetivos económicos, donde se minimizan los costos totales sujeto a limitaciones técnicas; objetivos técnicos, que optimiza el funcionamiento seguro y confiable de la red, reduciendo pérdidas de energía y variaciones de tensión; objetivos ambientales, para minimizar emisiones de contaminantes; u objetivos combinados (multi-objetivo) que considera todos los factores antes mencionados a través de su valoración económica [25].

La principal decisión de diseño en la planificación de una micro-red consiste en el dimensionamiento de la capacidad de los distintos elementos que componen el sistema para

garantizar su operación técnica y económicamente factible y sustentable. La mayor parte de lo reportado en la literatura tanto en investigación como en proyectos, el dimensionamiento de cada componente se obtiene mediante una simulación hora a hora del sistema, de acuerdo a los datos históricos meteorológicos y de demanda bajo un enfoque determinístico [26].

Para asistir en el dimensionamiento de micro-redes, existen diversos softwares de simulación, en el que destaca HOMER, descrito en la sección 4.1.2. Basado en el uso del algoritmo de optimización este software y su análisis de sensibilidad de resultados, en [27] Kolhe et al. se analiza una combinación óptima un sistema híbrido fotovoltaico / eólico / baterías / generador diésel para suministrar electricidad en una comunidad en la región de Siyambalanduwa, Sri Lanka. En [28] Liu et al. proponen un método de diseño de configuración óptima de una micro-red en Yantai, China, minimizando el costo de todo el ciclo de vida del sistema y considerando recaudación de impuestos a las emisiones de gases de efecto invernadero y confiabilidad del sistema, concluyendo con un análisis de sensibilidad de la velocidad del viento y radiación solar estimada. De la misma forma en [29] Su et al. se estudia una configuración óptima de micro-red en Ontario, Canadá, en un estudio de planificación a largo plazo considerando los futuros impactos medioambientales.

Por otra parte, en [30] Wang et al. elaboran una estrategia de planificación que garantiza la estabilidad de la micro-red a largo plazo, prolonga la vida útil de las baterías que componen el sistema de almacenamiento y maximiza el uso de la energía renovable, minimizando el costo presente neto (CPN) del ciclo de vida del proyecto. Luego, la efectividad de los resultados obtenidos es evaluada con una herramienta de simulación cuasi-estacionaria elaborada por el mismo autor llamada QSOT-MG.

En [31] Yu et al. proponen un método sistemático basado en la formulación de un problema de optimización de programación lineal entera mixta para seleccionar la cantidad óptima de componentes de generación y almacenamiento de una micro-red dado un perfil de carga típica, régimen de precios locales y costos de capital. La metodología es implementada en casos de estudio de sistemas fotovoltaicos y baterías de plomo-ácido en sitios residenciales, comerciales y desconectados de la red.

Relacionado estrechamente con la planificación de micro-redes, se han propuesto técnicas de inteligencia computacional para el dimensionamiento de DERs. En [32] Chakraborty et al. y en [33] Luo et al. presentan métodos basados en algoritmos evolutivos para optimizar el sistema de almacenamiento de energía para un sistema térmico / eólico, y para un sistema eólico remoto, respectivamente. Para la planificación de la red de distribución, en [34] Wang y Zhang proponen un algoritmo genético para resolver el problema de optimización multi-objetivo como un problema mono-objetivo; mientras que en [35] Zhao et al. realizan lo mismo para el dimensionamiento de las unidades de un micro-red en la isla de Dongfushan, China.

Gran parte del interés en el estudio de micro-redes consiste en que estos sistemas a futuro, sean una alternativa a la expansión tradicional de las redes de transmisión y distribución, que permitan reducir sus costos y aumentar su confiabilidad. En [36] Khodaei y Shahidehpour presentan un algoritmo para la planificación de micro-redes como alternativa a la co-optimización de la planificación de la generación y expansión de la transmisión de los grandes SEP. En este caso, el criterio de optimización busca minimizar el costo total de la planificación del sistema, que se

compone de los costos de inversión y operación de las micro-redes locales, de las grandes unidades de generación, y de las líneas de transmisión, junto con el costo esperado de la energía no servida.

Es importante notar que estos y otros estudios son abordados generalmente con un enfoque determinista, sin embargo, el problema de planificación de una micro-red está sujeta a diversas fuentes de incertidumbre, que tienen una influencia importante en las decisiones de planificación, pero que no es posible predecir con certeza.

Tal es el caso de la alta variabilidad presente en la carga y los recursos renovables, principalmente solar y eólica, que es necesario considerar en la planificación. En [37] Khodaei et al. proponen un proceso de planificación, donde se determina la viabilidad económica de una combinación óptima de DERs de una micro-red conectada a la red principal, considerando a través de modelos de optimización robusta los errores de predicción de la carga, de la generación renovable variable, de los precios de mercado y del “aislamiento” de la micro-red. Descomponiendo el problema en un problema principal de inversión y un subproblema de operación, donde las decisiones de diseño determinadas en la primera parte son puestas a prueba en el peor caso de operación, se concluye que la planificación con inclusión de incertidumbre optimizaría la operación de la micro-red.

En [38] Khodaei se resuelve un problema de planificación óptima de micro-redes “provisionales”, las que define como micro-redes que no poseen la capacidad de formación de islas y que dependen de una o más micro-redes eléctricamente conectadas. El problema de planificación en estos sistemas es definido considerando las interacciones anticipadas entre la micro-red, el resto de las micro-redes acopladas y la red de distribución durante los modos conectado y desconectado. La optimización robusta basada en la resolución de un problema de un conjunto poliédrico, con vértices definidos por los escenarios más desfavorables probables, es usada para representar de manera eficiente la incertidumbre de la información física y financiera.

Finalmente, en [39] Guo et al. presentan un método de planificación óptima multi-objetivo estocástico, y un modelo de programación con restricciones de probabilidad estocástica para lograr beneficios económicos y ambientales para una micro-red autónoma. La incertidumbre asociada a la velocidad del viento, índice de claridad y demanda es considerada en la sintetización de datos de series temporales basados en probabilidades de transiciones de las cadenas de Markov, método que descrito en la sección 2.7.

A continuación, se describen algunos estudios dedicados a la caracterización de fuentes de incertidumbre más importantes que influyen en la planificación y operación de un sistema eléctrico.

2.1.4. Caracterización de incertidumbre de los recursos renovables y carga.

En una micro-red las principales fuentes de incertidumbre están asociadas a las predicciones de las condiciones atmosféricas y de la demanda energética, las que además están fuertemente ligadas a la capacidad de generación de los DERs y abastecimiento del sistema. En este sentido, los métodos de inteligencia computacional han sido empleados para derivar modelos de ERNC y carga, debido a su capacidad para representar sistemas dinámicos no lineales [40], [41].

La tendencia actual de los SEP en evolucionar de sistemas centralizados a sistemas descentralizados de energía, donde la penetración de energías renovables, como la energía eólica y solar, aumentan significativamente el nivel de incertidumbre del sistema, y la gestión eficiente y confiable de energía se vuelve más relevante. Bajo este contexto, Quan et al. [42] presentan intervalos de predicción basados en redes neuronales para la estimación de la demanda eléctrica en Singapur y Nueva Gales del Sur (Australia), así como para la estimación de generación eólica del parque *Capital Wind Farm* (Australia), transformando el problema de optimización multi-objetivo a un problema mono-objetivo restringido, obteniendo mejores resultados comparativos en predicciones a corto plazo.

De igual forma, Khosravi et al. [43] dan énfasis en lo fundamental que es la predicción de la demanda para el funcionamiento confiable de los SEP, y que la incertidumbre asociada provoca una disminución importante en el desempeño de los modelos predictivos. Para esto, propone intervalos de predicción basados también en modelos de redes neuronales, que demuestran ser más fiables y útiles que una predicción de un valor puntual. Por otro lado, con el fin de aumentar la proliferación de sistemas de generación basados en energía solar, Jafarzadeh et al. [44] enfocan su trabajo en la modelación y predicción de plantas solares mediante distintos métodos de diseño de intervalos difusos de Takagi & Sugeno (T&S); mientras que en [45] Xia et al. proponen una técnica de inteligencia computacional híbrido que mezcla los métodos de redes neuronales y de lógica difusa para el pronóstico a 36 [hrs] de energía eólica de cada aerogenerador de un parque eólico, mediante la información disponible de un modelo climático a mesoescala y del registro de un sistema SCADA.

Por último, en [46] y [47], los autores presentan modelos de intervalos difusos para los recursos renovables y de carga, utilizando diversos métodos para su construcción. En [46] Sáez et al. proponen la caracterización de incertidumbre a través de la generación de intervalos difusos empleando el método de la covarianza (presentado en detalle en la sección 2.5.2.), para su implementación en el Sistema de Gestión de Energía (EMS por sus siglas en inglés) que, basado en la predicción de los recursos, coordina las distintas unidades de generación de una micro-red en Huatacondo, Chile. Estrechamente relacionado es el trabajo de Veltman et al. [47], donde proponen un novedoso algoritmo, llamado Optimización Basada en Aprendizaje de Enseñanza Mejorada ("*Improved Teaching Learning Based Optimization*"), para identificar los parámetros de los intervalos difusos de predicción del EMS.

En el presente trabajo de tesis se propone un novedoso método de planificación de micro-redes con la caracterización de la incertidumbre de los recursos renovables y carga a través de modelos empíricos basado en las metodologías y trabajo de los autores presentados, cuyo planteamiento y procedimiento es descrito a continuación.

2.2. Modelamiento de sistemas.

En función al grado de conocimiento que se tenga del sistema dinámico que desea modelar, la identificación de sistemas se divide en dos tipos: modelación fenomenológica, en la cual se tiene conocimiento de las ecuaciones que rigen el comportamiento físico de un sistema o proceso; y la modelación de caja negra o empírica, obtenida a partir de data experimental de entrada y salida.

A pesar de que los sistemas basados en el conocimiento de su comportamiento fenomenológico permiten un análisis directo entre las variables de interés, no siempre es posible identificar la dinámica del proceso debido a su complejidad y/o disponibilidad de medición de variables requeridas. En este sentido, los modelos empíricos presentan una ventaja comparativa, pues estos no requieren un conocimiento previo del sistema y son considerablemente más simples. Sin embargo, estos modelos corresponden solo a un ajuste matemático que permite representar el comportamiento del proceso solo dentro del rango para el cual fue diseñado [48].

Los modelos empíricos o también llamados de caja negra se clasifican en dos categorías: modelos lineales (en los parámetros), y modelos no lineales. Generalmente, en el proceso de modelación de un sistema dinámico, se comienza con la identificación de un modelo lineal, el cual es simple, fácil de diseñar y de implementar, sin embargo, dependiendo de la complejidad del sistema, es necesario recurrir a la modelación no lineal, que permite representar varias condiciones de operación.

En la presente sección se describirá la estructura general de un modelo lineal, para llegar a la representación particular de un modelo Auto-Regresivo (AR). Posteriormente se estudiará un caso específico de un modelo no lineal denominado modelo difuso de Takagi & Sugeno (T&S). Para ello, considérese un sistema en tiempo discreto t , con la notación $u(t)$ para la variable entrada, $y(t)$ para la variable de salida, y $e(t)$ para el conjunto de perturbaciones no medidas que afectan al sistema o proceso.

2.2.1. Modelación lineal.

La estructura general de un modelo lineal SISO (“*Single Input – Single Output*”) se muestra en la expresión (2.1).

$$G(q)y(t) = \frac{B(q)}{F(q)}u(t) + \frac{C(q)}{E(q)}e(t) \quad (2.1)$$

En donde $G(q)$, $B(q)$, $E(q)$, $F(q)$ corresponden a polinomios que contienen el operador de retardo temporal q (con $q^{-1}h(t) = h(t - 1) \quad \forall h(t)$), $y(t)$ es la salida del sistema, $u(t)$ es la entrada y $e(t)$ es error que se asume como ruido blanco no medido de media cero y varianza λ [49].

Por lo tanto, los polinomios se describen de la forma:

$$G(q) = 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_nq^{-n} \quad (2.2)$$

Donde, en este caso, n corresponde al número de retardos temporales de la salida.

El caso particular de los modelos AR afines, se cumple que $u(t) = 1(t)$, $G(q) \neq 0$, $B_1(q) = b_0$, $E(q) = D(q) = F_1(q) = 1$, por lo que el sistema queda descrito por (2.3).

$$G(q)y(t) = b_0 + e(t) \quad (2.3)$$

Expandiendo el polinomio, la expresión de estos modelos es:

$$y(t) = -a_1y(t-1) - \dots - a_ny(t-n) + b_0 + e(t) \quad (2.4)$$

Asimismo, es conveniente introducir el formato *theta* de manera de aislar el vector de parámetros que se deben estimar. El formato *theta* del sistema y del modelo son presentado en las expresiones (2.5) y (2.6) respectivamente.

$$y(t) = x(t)^T \theta + e(t) \quad (2.5)$$

$$\hat{y}_{lineal}(t) = x(t)^T \hat{\theta} \quad (2.6)$$

En donde $x(t)$ corresponde al vector de regresores, que en este caso es (2.7), o bien (2.8), donde $x_i(t)$ con $i \in \{0,1, \dots, n\}$ representan de forma general las variables (entradas y salidas) del modelo con sus respectivos retardos.

$$x(t)^T = [1(t) \quad y(t-1) \quad \dots \quad y(t-n)] \quad (2.7)$$

$$x(t)^T = [x_0(t) \quad x_1(t) \quad \dots \quad x_n(t)] \quad (2.8)$$

θ es el vector de parámetros del sistema y, por lo tanto $\hat{\theta}$ corresponde al vector de parámetros a estimar. En este caso, las definiciones (2.9) y (2.10) se considerarán equivalentes.

$$\theta = [b_0 \quad -a_1 \quad \dots \quad -a_n]^T \quad (2.9)$$

$$\theta = [\theta_0 \quad \theta_1 \quad \dots \quad \theta_n]^T \quad (2.10)$$

2.2.2. Modelación difusa de Takagi & Sugeno.

La forma de plantear la estructura de los modelos no lineales, les permite un mayor grado de flexibilidad y precisión a la hora de ajustarse al comportamiento de algunos procesos más complejos [50]. Dentro de esta categoría, los modelos más conocidos son las redes neuronales [51] y los modelos difusos, siendo estos últimos los de mayor interés en el presente trabajo.

Los modelos difusos están fundamentados en el concepto de lógica difusa propuesto por Zadeh en 1973 [52], donde se introduce la noción de variable lingüística, conjuntos y algoritmos difusos para representar comportamientos condicionales del estilo *Si-Entonces* (causa-efecto), definidos a partir del conocimiento intrínseco o información histórica que se posea de una planta o proceso. De esta forma, su dinámica se describe en (2.11) a partir de nociones conceptuales que abarquen un rango o grupo, denotando cierta incertidumbre o ambigüedad propia del proceso, y no de un valor determinístico dada por la lógica convencional.

$$\begin{array}{l} \text{Si} \quad x_1(t) \text{ es } MF_1 \text{ y } x_2(t) \text{ es } MF_2 \text{ y } \dots \text{ y } x_n(t) \text{ es } MF_n \\ \text{Entonces } y(t) \text{ es } MF_y \end{array} \quad (2.11)$$

Donde MF_y y MF_i con $i \in [1, \dots, n]$ son conjuntos difusos que representan el conocimiento cualitativo del proceso.

En la literatura se han propuesto diversos enfoques de modelación de sistemas difusos, donde se destacan los sistemas difusos de Mamdani (modelos difusos lingüísticos) [53] y los modelos difusos de Takagi & Sugeno (T&S) [54]. Estos últimos se detallan a continuación debido a su destacable versatilidad tanto en aplicaciones de control como de modelación de sistemas, siendo esto el foco principal del presente trabajo de investigación.

Takagi y Sugeno proponen una metodología que se caracteriza por estar basada en un conjunto de reglas definidas sobre sub-espacios difusos (funciones de pertenencias), donde las consecuencias (salidas) de estas reglas corresponden generalmente a relaciones lineales de entrada-salida. De esta forma, los modelos difusos de T&S permiten representar procesos con dinámicas no lineales mediante la información otorgada por modelos lineales [55]. Estos modelos pueden ser representados a partir de un conjunto de reglas del tipo “*Si-entonces*” de la forma (2.12).

$$\begin{array}{l} R^r: \text{Si} \quad x_1(t) \text{ es } MF_1^r \text{ y } x_2(t) \text{ es } MF_2^r \text{ y } \dots \text{ y } x_n(t) \text{ es } MF_n^r \\ \text{Entonces } y_r(x_p(t)) = f_r(x_p(t)) \end{array} \quad (2.12)$$

Con:

$$\begin{array}{l} r \in \{1, \dots, N_r\} \\ x_p(t) = [x_1(t) \quad \dots \quad x_n(t)] \end{array}$$

Donde R^r es la r -ésima regla del modelo difuso; $y_r(t)$ es su consecuencia o modelo local; N_r es el número total de reglas; $x_p(t)$ es el vector de premisas en el tiempo t , que por lo general son los regresores de la entrada y/o salida del sistema presentados en la sección 3.5.1, y que son combinadas entre sí utilizando operadores lógicos “y”; MF_i^r es el conjunto difuso (definido por su función de pertenencia) de la i -ésima premisa correspondiente a la r -ésima regla; y $f_r(x_p(t))$ es una función de las premisas del modelo, generalmente afin, presentado de forma general en (2.13), que representa una zona de operación específica.

$$y_r(x(t)) = \theta_{r,0} + \theta_{r,1}x_1(t) + \dots + \theta_{r,n}x_n(t) \quad (2.13)$$

Se define como $\mu_r(x_i(t))$ como el grado de pertenencia de la i -ésima premisa $x_i(t)$ al conjunto difuso MF_i^r en el instante t , donde $\mu_r(x_i(t)) \in [0,1]$ siendo 0 cuando la variable no pertenece a conjunto MF_i^r y 1 cuando pertenece completamente a él, pudiendo tomar valores intermedios. La función de pertenencia empleada en este caso para $\mu_r(x_i(t))$ corresponde a la función gaussiana presentada en (2.14).

$$\mu_r(x_i(t)) = \exp\left(-\frac{(x_i(t) - \bar{x}_{r,i})^2}{2\sigma_{r,i}}\right) \quad (2.14)$$

Donde $\bar{x}_{r,i}$ corresponde a la media de la función de pertenencia MF_i^r , y $\sigma_{r,i}$ corresponde a su desviación estándar.

Luego, es posible calcular el grado de activación de r -ésima regla $w_r(x_p(t))$ como (2.15).

$$w_r(x_p(t)) = \text{oper}\left(\mu_r(x_1(t)), \dots, \mu_r(x_n(t))\right) \quad (2.15)$$

Donde $\text{oper}(\cdot)$ corresponde al operador mínimo $\min(\cdot)$ o al operador producto $\text{prod}(\cdot)$, siendo este último el operador considerado en el presente trabajo.

Adicionalmente se define como $h_r(x_p(t))$ al grado de activación normalizado de la r -ésima regla, calculada como:

$$h_r(x_p(t)) = \frac{w_r(x_p(t))}{\sum_{k=1}^{N_r} w_k(x_p(t))} \quad (2.16)$$

Donde $h_r(x_p(t))$ satisface las siguientes condiciones:

$$\begin{aligned} h_r(x_p(t)) &> 0 \\ \sum_{r=1}^{N_r} h_r(x_p(t)) &= 1 \end{aligned}$$

Finalmente, la salida del modelo difuso de T&S $f^{TS}(x_p(t))$, representado de manera conceptual en la Figura 2.5, se obtiene como la suma ponderada de la respuesta de cada modelo local por su grado de activación normalizado, presentado en la expresión (2.17).

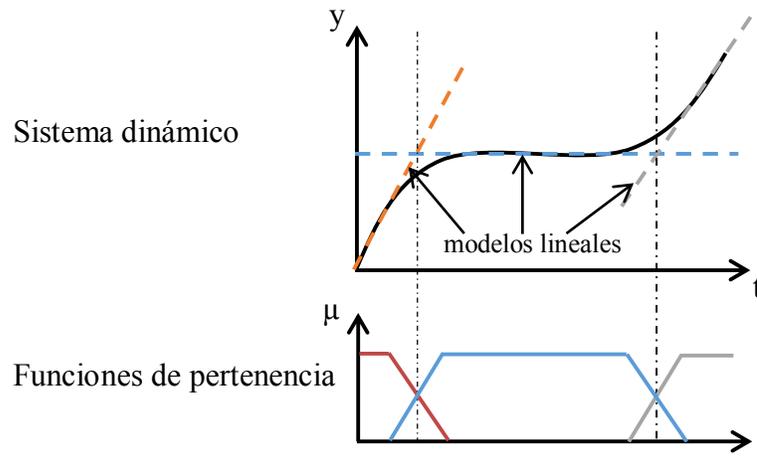


Figura 2.5: Aproximación lineal con modelo de T&S.

$$\hat{y}_{fuzzy} = f^{TS}(x_p(t)) = \sum_{r=1}^{Nr} h_r(x_p(t)) \cdot y_r(x_p(t)) \quad (2.17)$$

De esta forma, el modelo obtenido en (2.17) permite caracterizar las dinámicas no lineales del proceso que se desea representar, ya que de acuerdo a lo que establece Wang en [56], es un aproximador universal.

Llevando el modelo de T&S descrito a un caso particular y de interés para el presente trabajo, correspondiente a un modelo dinámico de tiempo discreto NAR (“*Nonlinear Autoregressive Model*”), es posible expresarlo partir de una base de reglas del tipo:

$$\begin{aligned} R^r: & \text{Si } y(t-1) \text{ es } MF_1^r \text{ y } \dots \text{ y } y(t-n) \text{ es } MF_n^r \\ & \text{Entonces } y_r(x_p(t)) = \theta_{r,0} + \theta_{r,1}y(t-1) + \dots + \theta_{r,n}y(t-n) \end{aligned} \quad (2.18)$$

O bien en el formato *theta*:

$$\begin{aligned} R^r: & \text{Si } x_1(t) \text{ es } MF_1^r \text{ y } \dots \text{ y } x_n(t) \text{ es } MF_n^r \\ & \text{Entonces } y_r(x_p(t)) = x(t)^T \theta_r \end{aligned} \quad (2.19)$$

Con:

$$x(t) = [1, x_1(t), \dots, x_n(t)] \quad (2.20)$$

$$\theta_r = [\theta_{r,0}, \theta_{r,1}, \dots, \theta_{r,n}] \quad (2.21)$$

Donde $x_p(t)$ y $x(t)$ son el vector de las premisas y de las consecuencias del modelo respectivamente, y θ_r es el vector de parámetros de la r-ésima regla.

2.3. Identificación de sistemas.

En el diseño de modelos lineales y difusos de T&S definidos en la sección 2.2.1. y 2.2.2. respectivamente se requiere definir una serie de variables y parámetros que no se conocen a priori, por lo que estructura apropiada para representar un sistema es desconocida. Para ello, la identificación de sistemas corresponde a la disciplina que busca describir matemáticamente un modelo de un sistema dinámico a partir de una serie de mediciones de un sistema [57].

El proceso identificación de un sistema se presenta en la Figura 2.6. Es necesario notar que proceso es iterativo, de modo que si se obtiene un modelo que no cumpla con el desempeño esperado, es posible regresar a una de sus etapas y repetir el proceso hasta alcanzar el estándar deseado.

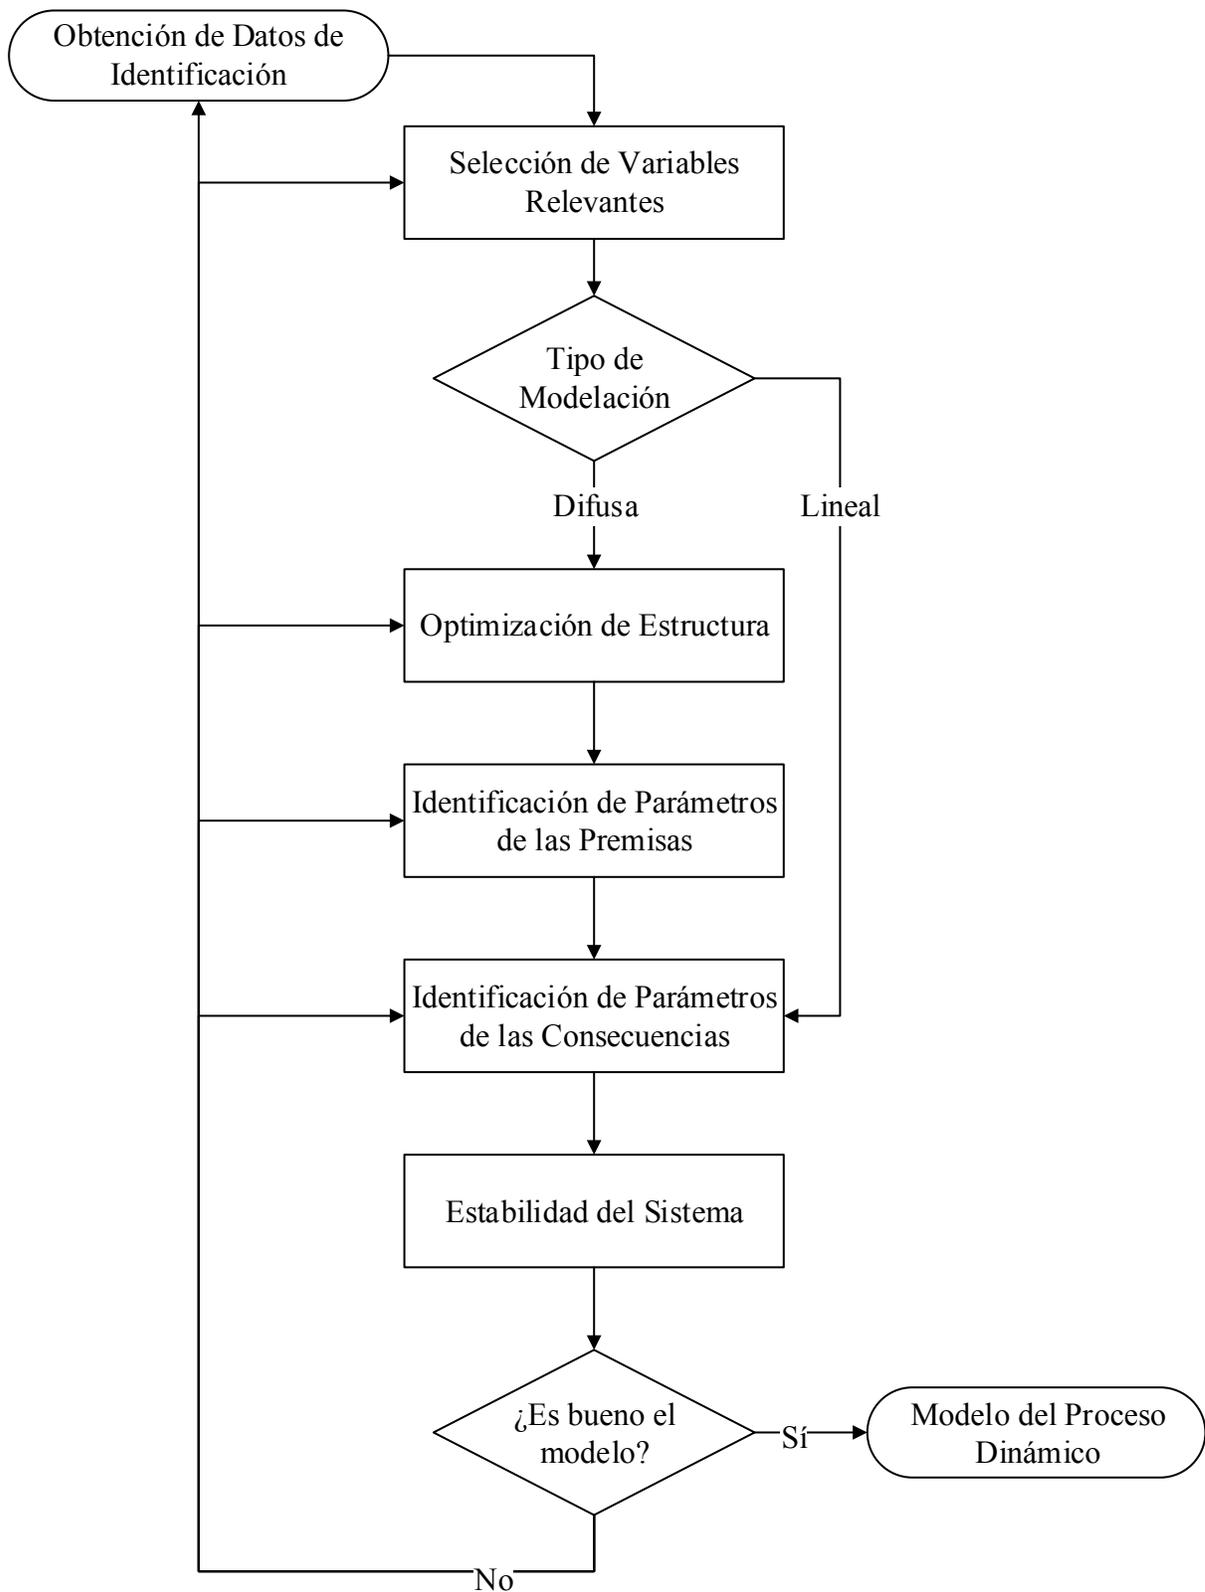


Figura 2.6: Proceso de identificación de sistemas.

A continuación, se describe cada una de las etapas del procedimiento empleado.

2.3.1. Obtención de datos de identificación.

La obtención de datos para una identificación de un sistema dinámico consiste en recolectar información del comportamiento del sistema tanto en estado estacionario como en estado transiente bajo condiciones de operación [50]. En general, el proceso se realiza con una entrada de excitación persistente al sistema, registrando simultáneamente dicha variación junto con el impacto que estos cambios producen sobre la salida del sistema. Sin embargo, cuando no se tiene acceso a la manipulación en la entrada, es importante contar con un registro lo suficientemente variable que cumpla las condiciones de excitación persistente.

Las etapas más relevantes en la obtención de datos consisten en la determinación del tiempo de muestreo, selección de variables de entradas candidatas del sistema y pre-procesamiento de datos para la detección y eliminación de valores anómalos.

Para la identificación de sistemas, es necesario separar los datos obtenidos en tres conjuntos independientes [58]:

- **Entrenamiento:** Conjunto extenso de datos destinado para la identificación del modelo propiamente tal, empleado para el cálculo de sus parámetros.
- **Test:** Datos destinados a evaluar la capacidad de generalización del modelo diseñado y de esta forma seleccionar su estructura.
- **Validación:** Datos utilizados para evaluar el desempeño a través de la medida del error del modelo final obtenido para analizar su capacidad de generalización.

No existe una regla general que determine la proporción o cantidad de datos requerida para cada conjunto, ya que esto depende principalmente de la aplicación para el que se desea implementar el modelo. En [58] Hastie et al. proponen una división de 50% de los datos para el conjunto de entrenamiento, 25% para el conjunto de test y 25% para el conjunto de validación, mientras que en *MathWorks* [59] la propuesta consiste en un 70% de datos para entrenamiento, 15% para test y 15% para validación. Para el presente trabajo se opta por utilizar un valor intermedio correspondiente a un 60% de entrenamiento, 20% de test y 20% de validación, con la consideración de que, al trabajar con series de tiempo, la separación y selección de datos debe realizarse de tal manera de respetar la causalidad de los procesos.

Una vez obtenidos los datos de entrada-salida y dividirlos en los conjuntos mencionados, se procede con la siguiente etapa, que consiste en seleccionar las variables relevantes del modelo.

2.3.2. Selección de variables relevantes.

En modelos de tiempo discreto, es necesario seleccionar las variables relevantes, tanto entradas como salida, y respectivos retardos que tengan mayor relación con el comportamiento observado en la salida de la planta o proceso. Este procedimiento es posible efectuarlo utilizando el conocimiento previo dado por la experiencia que se tenga para hacer la selección, sin embargo, existen otras alternativas basadas en la evaluación del impacto que tienen las variables candidatas en la salida del modelo.

El principal indicador de desempeño utilizado en el proceso de identificación de sistemas corresponde al Error Cuadrático Medio (RMSE por sus siglas en inglés), que consiste en una medida de error de predicción obtenida por la diferencia entre los valores pronosticados por un modelo y los valores medidos, agrupada en una sola medida. Otro indicador de desempeño cuya medida de error es similar corresponde al Error Absoluto Medio (MAE por sus siglas en inglés), el cual también es utilizado en el presente trabajo. Las expresiones del RMSE y del MAE vienen dada por (2.22) y (2.23) respectivamente.

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y(t) - \hat{y}(t))^2} \quad (2.22)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |y(t) - \hat{y}(t)| \quad (2.23)$$

Donde $y(t)$ corresponde a la salida real del proceso, $\hat{y}(t)$ es la salida predicha por el modelo y N es la cantidad total de datos.

Para el caso de identificación de modelos lineales, se propone un criterio cuantitativo de comparación de modelos denominado Criterio de Información de Akaike (AIC por sus siglas en inglés) que, en función de la teoría del mismo nombre, el modelo que presente un menor AIC es el más certero [60]. De esta forma, este método consiste en minimizar el índice de AIC de la expresión (2.24) para determinar la mejor estructura del modelo. Este criterio busca, por un lado, reducir el error de predicción, al mismo tiempo de penalizar la sobre-parametrización del modelo ya que, si se ajusta demasiado al conjunto de datos de entrenamiento, impediría la correcta predicción con un conjunto de datos distinto.

$$AIC = \log(RMSE) + \frac{2m}{N} \quad (2.24)$$

Donde $RMSE$ es el error de predicción del modelo, m es su cantidad de parámetros y N es la cantidad total de datos.

Para la selección de variables relevantes en la identificación de modelos difusos se puede utilizar el método heurístico [61], un estudio de correlación / autocorrelación de variables candidatas [62], o bien, un análisis de sensibilidad [63], siendo este último el empleado en el presente trabajo.

El análisis de sensibilidad consiste en estudiar la influencia de cada premisa sobre la salida del modelo difuso [63]. Para ello se deben calcular las derivadas de (2.25).

$$\xi_i(x_p(t)) = \frac{\partial \hat{y}_{fuzzy}(t)}{\partial x_i(t)} \quad (2.25)$$

Con $i \in \{1, \dots, n\}$, donde $\xi_i(x_p(t))$ es la sensibilidad de la i -ésima premisa $x_i(t)$, n es la cantidad total de premisas e $\hat{y}_{fuzzy}(t)$ es la salida del modelo difuso. La sensibilidad de cada variable representa la relevancia de dicha premisa en la salida del modelo difuso, por lo que las variables candidatas deben ser normalizadas si es necesario para evitar la influencia de diferencias de magnitud entre ellas.

Considerando el modelo difuso presentado en (2.18), es posible calcular explícitamente la derivada (2.25) que define la sensibilidad, obteniendo (2.26) donde es necesario recordar la dependencia de $x_i(t)$ en los grados de activación $w_r(x_p(t))$ y las salidas de los modelos locales $y_r(x_p(t))$.

$$\xi_i(x_p(t)) = \frac{\sum_{r=1}^{N_r} \left(\frac{\partial w_r}{\partial x_i(t)} y_r + \frac{\partial y_r}{\partial x_i(t)} w_r \right) \sum_{r=1}^{N_r} w_r - \sum_{r=1}^{N_r} \left(\frac{\partial w_r}{\partial x_i(t)} \right) \sum_{r=1}^{N_r} w_r y_r}{\left(\sum_{r=1}^{N_r} w_r \right)^2} \quad (2.26)$$

Con:

$$\frac{\partial y_r(x_p(t))}{\partial x_i(t)} = \theta_{r,i} \quad (2.27)$$

Y definiendo $c_{r,i}$ como:

$$c_{r,i}(x_p(t)) = -\frac{x_i(t) - \bar{x}_{r,i}}{\sigma_{r,i}} \times \frac{1}{\sigma_{r,i}} \quad (2.28)$$

Se tiene que la sensibilidad $\xi_i(x_p(t))$ con respecto a la premisa $x_i(t)$ es:

$$\xi_i(x_p(t)) = \frac{\sum_{r=1}^{N_r} (w_r c_{r,i} y_r + \theta_{r,i} w_r) \sum_{r=1}^{N_r} w_r - \sum_{r=1}^{N_r} (w_r c_{r,i}) \sum_{r=1}^{N_r} w_r y_r}{(\sum_{r=1}^{N_r} w_r)^2} \quad (2.29)$$

Luego, evaluando las sensibilidades de todas las premisas candidatas en el conjunto de datos de entrenamiento, se obtiene su representatividad en distintos puntos de operación, con lo que se obtiene un vector $\bar{\xi}_i(x_p(t))$ para cada una de ellas. Posteriormente, se propone el índice de sensibilidad (2.30).

$$I_i(x_p(t)) = \mu^2(\bar{\xi}_i(x_p(t))) + \sigma^2(\bar{\xi}_i(x_p(t))) \quad (2.30)$$

Donde $\mu(\bar{\xi}_i(x_p(t)))$ corresponde a la media de la sensibilidad de la i -ésima premisa, mientras que $\sigma(\bar{\xi}_i(x_p(t)))$ indica la varianza de los datos de sensibilidad de la misma premisa. De esta manera, $I_i(x_p(t))$ evita valores sesgados de representatividad de las variables candidatas. Finalmente, se escoge las premisas con mayor índice de sensibilidad y se descartan las restantes. Este procedimiento se puede realizar definiendo un umbral para descartar todas las variables candidatas que posean un índice menor a dicho umbral, o bien, como se ha realizado en el presente trabajo, iterativamente, descartando la variable con menor índice en cada iteración y evaluando su rendimiento en el conjunto de test.

Luego del proceso de selección de las variables relevantes del modelo es necesario determinar la estructura óptima del modelo difuso mediante el criterio de desempeño indicado a continuación.

2.3.3. Optimización de la estructura.

La estructura de un modelo difuso, detallada en la sección 2.2.2. se encuentra definida por el tipo de funciones $f_r(x_p(t))$, la forma de las funciones de pertenencia MF_i^r , y por el número de reglas N_r que lo compone. Generalmente, tanto $f_r(x_p(t))$ como MF_i^r son escogidas por anterioridad a la etapa de identificación del modelo y, por lo tanto, esta etapa se centra en determinar el número óptimo de reglas del modelo difuso. Es importante mencionar que este procedimiento no se realiza en la identificación de modelos lineales, ya que estos se podrían considerar como modelos difusos de una sola regla.

El proceso de optimización de la estructura relacionado con la cantidad de reglas consiste en la minimización de algún criterio de comparación entre distintos las salidas estimadas de los modelos determinados y la salida real [63]. Para ello se propone entrenar distintas arquitecturas, obtener sus parámetros y comparar sus desempeños en el conjunto de datos de test. De los diversos criterios

cuantitativos de comparación de modelos que existen, se empleará el RMSE definido en (2.22) como índice de desempeño para la evaluación en el conjunto de test.

Posteriormente, ya determinada la cantidad de reglas óptimo del modelo difuso, se requiere determinar sus parámetros, tanto de sus premisas como de sus consecuencias. Algunos autores plantean la identificación de ambos parámetros como un único problema de optimización, donde se busca su ajuste minimizando una función de costos [64], [65]. Sin embargo, plantear el problema de identificación de parámetros de premisa y consecuencia simplifica la construcción del modelo, permitiendo la resolución de problemas más simples, pero con la posibilidad de obtener una solución sub-óptima. Por otro lado, esta simplificación permite la inclusión de funciones más complejas en las consecuencias sin aumentar demasiado la complejidad del sistema [66] por lo que se opta este enfoque para la identificación de parámetros.

2.3.4. Identificación de los parámetros de las premisas.

Esta etapa consiste en identificar los parámetros que definen a las funciones de pertenencia MF_i^r del modelo difuso, las que pueden ser determinadas a través de *clustering* difuso. Esta técnica corresponde a un método de aprendizaje no supervisado, que no requiere de una clasificación a priori de datos, ni conocimiento sobre la información que se desea agrupar [67].

Dentro de las técnicas de determinación de *clusters* es posible diferenciar dos tipos de algoritmos. El primero de ellos, llamado *Hard Clustering* (*Clustering* convencional), considera el grado de pertenencia $\mu_r(x_i(t))$ de manera binaria, asignando el valor de 1, si el dato pertenece a un determinado *cluster* y 0 si no pertenece a él [68]. Un ejemplo de este tipo de algoritmo es *k-means*, presentado en la sección A.2. del Anexos.

En el segundo tipo de algoritmo, denominado *Fuzzy Clustering* (*Clustering* difuso), se define como *cluster* difuso a un conjunto de datos que poseen cierta similitud entre sí, pero que a su vez poseen distinta información de otro *cluster* [69]. De esta forma, cada *cluster* representa una clase, y en términos de los modelos difusos, éstos representan las reglas del sistema. A diferencia del *clustering* convencional, los elementos que componen un *cluster* difuso tienen asociado un grado de pertenencia que va desde 0 a 1, siendo así posible pertenecer a múltiples clases con distintos grados de pertenencia para cada uno de ellos.

En *clustering* difuso se destacan algoritmos como *Fuzzy c-means* [68], aquellos basados en prototipos lineales y otros en matrices de covarianza difusa, en el que destaca el algoritmo de Gustafson-Kessel [70], utilizado en el presente trabajo. Estos algoritmos consisten en distintos métodos para encontrar los centros de los *clusters* y los grados de pertenencia de los datos mediante la minimización de la siguiente función de costos presentada en (2.31).

$$J(Z, U, V) = \sum_{i=1}^c \sum_{t=1}^N (\mu_{it})^m D_{itM}^2 \quad (2.31)$$

$$D_{itM}^2 = (x_t - v_i)^T M (x_t - v_i) \quad (2.32)$$

Con:

$$\begin{aligned} X &= [x_1, \dots, x_N] \\ V &= [v_1, \dots, v_c], \quad v_i \in \mathbb{R}^n \\ m &\in [1, \infty[\end{aligned}$$

Donde X es la matriz de datos de entradas x_t del sistema; U es la matriz de partición de datos, que contiene los grados de pertenencia μ_{it} del k -ésimo dato al i -ésimo *cluster*; V es un vector con los centros de los *clusters* v_i (que serán determinados); c es el número de *clusters* (fijado previo a la optimización); N es la cantidad de datos; D_{itA}^2 es una norma de distancia; M es una matriz positiva definida que induce la norma a utilizar; y m es un factor de ajuste, generalmente igual a 2 [67], para modificar la difusividad de los *cluster* obtenidos, donde $m = 1$ implica una partición no difusa, es decir $\mu_{it} \in \{0,1\}$, mientras si tiende a infinito, la partición se vuelve completamente difusa.

Si en la expresión (2.32), se escoge la matriz M como la identidad, se inducirá la norma euclideana para encontrar los *clusters*, teniéndose así el algoritmo *Fuzzy c-means*. Por otro lado, si se deja como parámetro de optimización, se le permite al algoritmo inducir en su formulación distancias adaptativas, lo cual permite encontrar *clusters* con distintas formas. Este el enfoque que es abordado en algoritmos de *clustering* con matriz de covarianza difusa, como Gustafson-Kessel. En este caso, se encuentra una matriz M_i para cada *cluster*, por lo que la métrica de distancia (2.32) se replantea a la forma:

$$D_{itM_i}^2 = (x_t - v_i)^T M_i (x_t - v_i) \quad (2.33)$$

Sin embargo, para evitar que la norma de M_i tienda a 0 para minimizar la función objetivo e invalidando la influencia de las demás variables de optimización, se incluye la restricción de volumen (2.34).

$$\det(M_i) = \rho_i, \quad \rho > 0, \quad \forall i \quad (2.34)$$

Lo que permite a M_i optimizar la forma del *cluster*, manteniendo su volumen constante. Típicamente se toma $\rho_i = 1, \forall i$.

Realizado el *clustering*, es posible proyectar las agrupaciones obtenidas en el espacio de entrada y ajustar funciones paramétricas para describir los conjuntos difusos MF_i^r . En este caso, se asume que los datos distribuyen normalmente en el espacio vectorial formada por las entradas y , por lo tanto, las funciones de pertenencia tienen la forma de funciones gaussianas presentadas en (2.14).

De esta forma, una vez identificados los *clusters* a partir de los datos mediante el algoritmo de Gustafson-Kessel, se proyectan sobre el espacio de las variables de entrada al modelo, y sobre dichas proyecciones se ajustan a curvas gaussianas para encontrar $\bar{x}_{r,i}$ y $\sigma_{r,i}$, tal como se muestra en el ejemplo de la Figura 2.7.

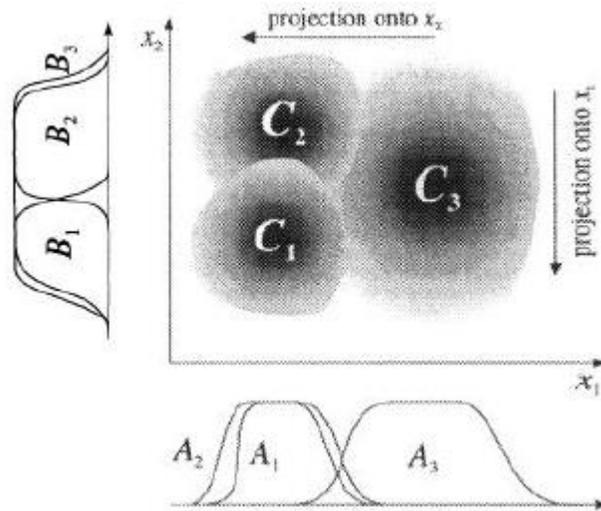


Figura 2.7: Proyección de 3 *clusters* en 2 variables de entrada [67].

Una vez terminados estos valores, el paso siguiente es determinar los parámetros de las consecuencias que definen al modelo.

2.3.5. Identificación de los parámetros de las consecuencias.

En tiempo discreto, la salida del modelo identificado se encuentra en función de los retardos de sus de sus entradas y salida. En el caso de la identificación de modelos difusos, esta etapa depende también del tipo de función $f_r(x_p(t))$ escogida como consecuencia de cada regla $y_r(x_p(t))$, sin embargo, es usual utilizar modelos afines de la forma (2.13). Así este proceso de estimación de parámetros, tanto en modelación lineal como difusa, consiste en seleccionar el vector de parámetros θ que optimice alguna función objetivo en particular.

En este trabajo se utilizará el método de mínimos cuadrados (*Least Square Error*) [62] que consiste en minimizar el error de predicción a un paso del modelo $\varepsilon(t)$, definido como:

$$\varepsilon(t) = y(t) - \hat{y}(t, \theta) \quad (2.35)$$

Donde $y(t)$ es la salida medida del proceso medido en el instante t e $\hat{y}(t, \theta)$ representa la predicción en el instante t , utilizando θ como parámetros de los modelos locales, resultante de

\hat{y}_{lineal} de la expresión (2.6) si se está identificando un modelo lineal o \hat{y}_{fuzzy} obtenida de (2.17) si el proceso es de identificación difusa.

Formalmente, el problema de optimización, para encontrar los parámetros estimados $\hat{\theta}$, se define como:

$$\min_{\theta} J(\hat{\theta}) = \mathbb{E} \left\{ (y(t) - \hat{y}(t, \theta))^2 \right\} \quad (2.36)$$

El cual, si se considera una ventana de tiempo suficientemente amplio y si el proceso a modelar es ergódico, es decir, su promedio temporal tiende a su valor esperado cuando el tiempo tiende a infinito, la expresión (2.36) se puede calcular como (2.37) [62].

$$\min_{\theta} J(\hat{\theta}) = \sum_{t=1}^N (y(t) - \hat{y}(t, \theta))^2 \quad (2.37)$$

Donde N es la cantidad de datos. Este planteamiento permite obtener una solución analítica al problema de optimización, dada por (2.38) para la identificación de un modelo lineal.

$$\hat{\theta}_{lineal} = (X^T X)^{-1} X^T Y \quad (2.38)$$

Con:

$$Y = \begin{bmatrix} y(1) \\ \vdots \\ y(N) \end{bmatrix} \quad (2.39)$$

$$X = \begin{bmatrix} X(1) \\ \vdots \\ X(N) \end{bmatrix} = \begin{bmatrix} x_1(1) & \dots & x_n(1) \\ \vdots & \ddots & \vdots \\ x_1(N) & \dots & x_n(N) \end{bmatrix} \quad (2.40)$$

Donde X es la matriz de datos de entradas del sistema, e Y corresponde al vector de datos de su salida.

Para el caso de la identificación de un modelo difuso, la solución al problema de optimización viene dada por (2.41).

$$\hat{\theta}_{fuzzy} = (X_{fuzzy}^T X_{fuzzy})^{-1} X_{fuzzy}^T Y \quad (2.41)$$

Con:

$$X_{fuzzy} = \begin{bmatrix} h_1(x(1))x_1(1) \dots h_{N_r}(x(1))x_1(1) & \dots & h_1(x(1))x_n(1) \dots h_{N_r}(x(1))x_n(1) \\ \vdots & \ddots & \vdots \\ h_1(x(N))x_1(N) \dots h_{N_r}(x(N))x_1(N) & \dots & h_1(x(N))x_n(N) \dots h_{N_r}(x(N))x_n(N) \end{bmatrix} \quad (2.42)$$

2.3.6. Análisis de estabilidad.

Finalmente, es necesario estudiar la estabilidad del modelo diseñado, pues este define la capacidad de la salida del sistema de volver a un punto de equilibrio cuando está sujeto a una condición inicial [71], entendiéndose como punto de equilibrio aquel estado en el cual la salida del sistema permanece invariante ante la ausencia de señales de entrada y perturbaciones. Esta condición cobra importancia en el presente trabajo, pues si el sistema inestable, la salida divergirá con respecto a dicho estado de equilibrio.

En esta fase, se analiza la estabilidad de los distintos modelos identificados que, en el caso de la identificación lineal de sistemas de tiempo discreto, esto se limita únicamente al análisis de los polos del modelo, buscando que estos se encuentren al interior del círculo unitario en el plano Z . En cambio, en identificación de modelos difusos de T&S se requiere un análisis más elaborado presentado a continuación en la sección 2.4. , para luego escoger la mejor estructura estable de un modelo en función de su RMSE en el conjunto de datos de test.

Para ambos casos, si los modelos identificados no cumplen el criterio de estabilidad, es necesario regresar a algunas de las etapas anteriores y proceder con una nueva iteración para obtener un nuevo modelo. Por otro lado, si el modelo obtenido es estable y presenta el desempeño deseado, se selecciona como el modelo que representa al proceso dinámico y se da por finalizado el procedimiento de identificación.

2.4. Estabilidad de Modelos Difusos.

Es la presente sección se presenta la metodología empleada planteada por Tanaka y Sugeno para el estudio de estabilidad de los sistemas difusos [72], modelos que, al ser esencialmente sistemas no lineales, su análisis de estabilidad no ha sido una tarea fácil [73].

La metodología expuesta se encuentra basada en el método de Lyapunov, cuya revisión se muestra a continuación, para luego detallar la técnica utilizada como herramienta para realizar el análisis de estabilidad en el presente trabajo.

2.4.1. Estabilidad según Lyapunov.

El teorema de estabilidad de Lyapunov, propuesto hace más de 100 años, es uno de los teoremas más importantes en control. Las funciones de Lyapunov son las herramientas básicas para analizar la estabilidad de sistemas no lineales [74]. Se dice que un punto es estable si todas las soluciones que se inicien en una vecindad de dicho punto permanecen cerca de él; en caso contrario, el punto de equilibrio es inestable. Además, un punto de equilibrio es asintóticamente estable si todas las soluciones que se inicien en las cercanías de él tienden hacia dicho punto a medida que el tiempo tiende a infinito.

El teorema de Lyapunov en tiempo discreto [75] dice que si se tiene un sistema del tipo:

$$x(t + 1) = f(x(t)) \quad (2.43)$$

Tal que $f(0) = 0$, y además existe una función escalar $V(x(t))$ tal que:

$$\begin{aligned} V(0) &= 0 \\ V(x(t)) &> 0, & \forall x(t) \neq 0 \\ \Delta V(x(t)) &= V(x(t)) - V(x(t - 1)) \leq 0, & \forall x(t) \neq 0 \end{aligned} \quad (2.44)$$

Entonces el estado $x(t) = 0$ es un punto de equilibrio estable. A su vez, en caso de que $\Delta V(x(t)) < 0$, entonces el estado $x(t) = 0$ es asintóticamente estable.

2.4.2. Estabilidad de modelos difusos discretos.

Es posible analizar la estabilidad de los modelos difusos de T&S al determinar la existencia de una matriz P dada por los teoremas presentados a continuación.

- **Teorema** [72]: Sea el sistema descrito en variables de estado como:

$$x(t + 1) = Ax(t) \quad (2.45)$$

El sistema (2.45) es asintóticamente estable si existe una matriz común P tal que:

$$A_r^T P A_r - P < 0, \quad \forall r \in \{1, \dots, N_r\} \quad (2.46)$$

Se debe notar que, aunque cada subsistema de un modelo difuso de T&S sea estable, la existencia de P no está asegurada. A través del siguiente teorema, se da la condición suficiente para garantizar su existencia.

- **Teorema [72]:** Sea A_r es estable y no-singular para $r \in \{1, \dots, N_r\}$, con A_r , Entonces la matriz $A_r A_q$, con $r, q \in \{1, \dots, N_r\}$, es estable si existe una matriz común definida positiva P tal que (2.46) se satisface.

En efecto, de (2.46) se obtiene la implicancia directa:

$$A_r^T P A_r < P, \quad \forall r \in \{1, \dots, N_r\} \quad (2.47)$$

Por otro lado, dado que $(A_r^{-1})^T = (A_r^T)^{-1}$, de (2.46) se tiene:

$$P - (A_r^{-1})^T P A_r^{-1} < 0 \quad (2.48)$$

$$P < (A_r^{-1})^T P A_r^{-1}, \quad \forall r \in \{1, \dots, N_r\} \quad (2.49)$$

Luego, con (2.48) y (2.53) se llega a:

$$A_r^T P A_r < (A_q^{-1})^T P A_q^{-1}, \quad \forall r, q \in \{1, \dots, N_r\} \quad (2.50)$$

De esta desigualdad se obtiene finalmente (2.51).

$$(A_r A_q)^T P A_r A_q - P < 0, \quad \forall r, q \in \{1, \dots, N_r\} \quad (2.51)$$

Por lo que $A_r A_q$ debe ser estable para $r, q \in \{1, \dots, N_r\}$.

2.4.3. Metodología para análisis de estabilidad de modelos difusos.

Basado en los teoremas presentados en la sección 2.4.2. es posible desarrollar una metodología para analizar la estabilidad del sistema difuso [55]. El diagrama de flujo del proceso de análisis es presentado en la Figura 2.8, cuyo detalle es explicado a continuación.

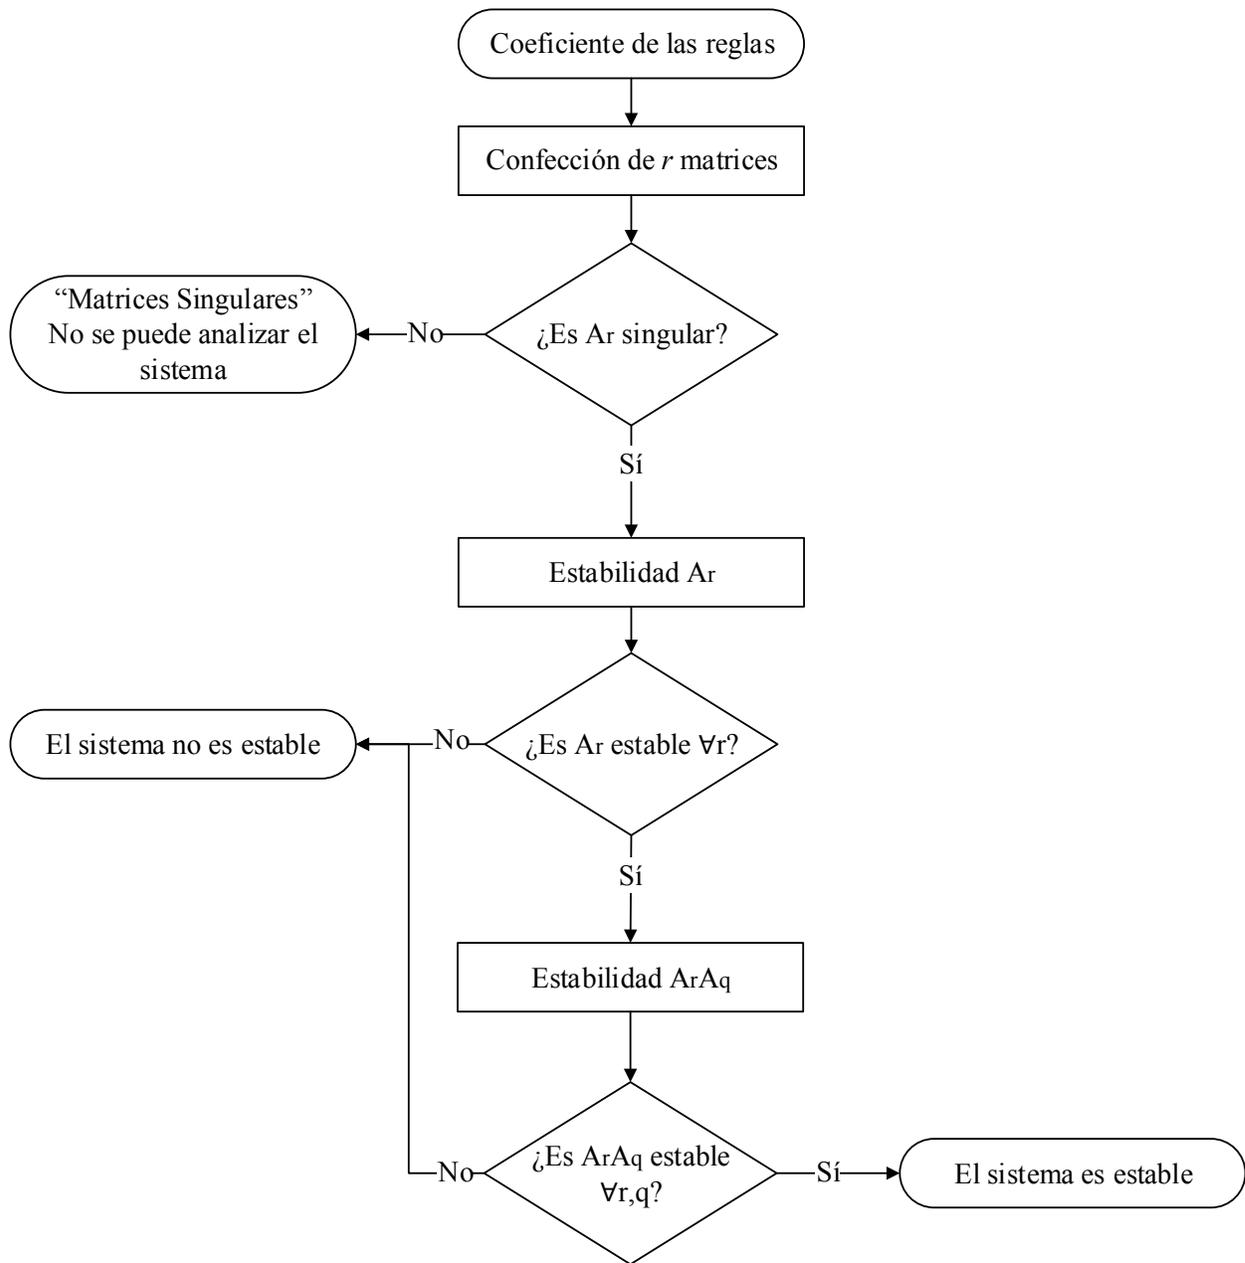


Figura 2.8: Metodología para el análisis de estabilidad de modelos difusos de T&S [55].

Coeficiente de las reglas: Se considera como entrada una matriz G que contenga los parámetros del modelo de las consecuencias de cada regla del modelo difuso. De esta forma, para un modelo de T&S representada de la forma (2.18), dicha matriz tendrá la estructura que se muestra en (2.52).

$$G = \begin{bmatrix} a_{1,1} & \cdots & a_{1,n} \\ \vdots & \ddots & \vdots \\ a_{N_r,1} & \cdots & a_{N_r,n} \end{bmatrix} \quad (2.52)$$

Donde N_r es la cantidad de reglas y n es el número de regresores.

Confección de r matrices: Se construyen las N_r matrices que representan el modelo en variables de estado. Para ello, asumiendo que los modelos locales son controlables, se pueden utilizar su representación en su forma canónica controlable, definidos como (2.53) para todo $r \in \{1, \dots, N_r\}$.

$$A_r = \begin{bmatrix} a_{r,1} & a_{r,2} & \cdots & \cdots & a_{r,n} \\ 1 & 0 & \cdots & \cdots & 0 \\ 0 & \ddots & \ddots & & \vdots \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ 0 & \cdots & 0 & 1 & 0 \end{bmatrix} \quad (2.53)$$

Singularidad A_r : El teorema exige que las matrices no sean singulares, por lo tanto, se calcula el determinante de las N_r matrices y se asegura que sean distinto de cero. En caso contrario, el procedimiento de estudio de estabilidad termina y no se puede analizar el sistema utilizando esta técnica y, por lo tanto, no se asegura estabilidad. Si ninguna de las matrices A_r es singular, se continúa con la siguiente etapa.

Estabilidad A_r : La estabilidad de las matrices se analiza a través de sus polos. Al tratarse de un sistema discreto, se busca que dichos polos se encuentren dentro del círculo unitario. Si alguna de las matrices A_r resulta no ser estable, entonces se termina el procedimiento y se determina que el sistema es inestable. En caso contrario, se prosigue con la siguiente etapa.

Estabilidad $A_r A_q$: Finalmente se realiza multiplicación de las matrices $A_r \cdot A_q$, obteniéndose N_r^2 nuevas matrices a las que se les realiza el mismo procedimiento anterior para determinar su estabilidad. Si alguna de estas matrices resulta no ser estable, entonces se establece que el modelo es inestable. En cambio, si todas las matrices $A_r A_q$ resultan ser estables, entonces el modelo de T&S es estable.

2.5. Modelos de intervalos.

2.5.1. Generalidades.

La incertidumbre siempre estará intrínseca en el proceso de aproximar un sistema a una función mediante un conjunto finito de datos medidos, donde existirá parte de su dinámica que no será modelada. Otra fuente de incertidumbre importante se encuentra asociada al efecto de las perturbaciones externas no medidas que actúan sobre una planta o sistema y que afectan en su salida. Debido a esto, el desempeño del modelo identificado dependerá tanto de la calidad de los datos con los que se cuente para realizar su identificación, como de la magnitud del efecto de las perturbaciones en la operación del sistema [48].

De acuerdo con lo expuesto, es necesario caracterizar la incertidumbre de modo que ésta sea incluida en la representación del proceso a identificar mediante un modelo empírico, por lo que diversos autores han abordado este desafío a través de distintos enfoques. En este contexto, Škrjanc et al. [76] introducen el concepto de modelo de intervalo difuso para ser utilizado en detección de fallas, que consiste en el diseño de un modelo difuso de T&S con parámetros superiores e inferiores, de tal forma que un porcentaje dado de los valores medidos se encuentren contenidos en la salida de dicho modelo.

En el presente trabajo, basado en los conceptos expuestos, se aborda la cuantificación de la incertidumbre asociada a un proceso mediante intervalos de confianza representada por una función superior $\bar{f}(x_p(t))$ y una función inferior $\underline{f}(x_p(t))$, tal que satisfaga (2.54).

$$\underline{f}(x_p(t)) \leq y(t) \leq \bar{f}(x_p(t)) \quad (2.54)$$

Donde $x_p(t)$ denota las premisas del modelo e $y(t)$ corresponde a la salida medida del sistema.

Para encontrar las funciones $\bar{f}(x_p(t))$ y $\underline{f}(x_p(t))$ existen dos metodologías: el método min-max [76] y el método de la covarianza [77], siendo este último el empleado en el presente trabajo.

2.5.2. Método de la covarianza.

La caracterización de la incertidumbre mediante identificación de intervalos difusos por el método de la covarianza se basa en utilizar la covarianza del error entre los datos reales y la estimación de los modelos locales del sistema difuso, de tal manera de determinar los parámetros de las funciones difusas limitantes a partir de cada consecuencia, y así establecer un rango de confianza para la salida estimada del sistema obtenida por el modelo [77]. El requerimiento principal al definir la banda del intervalo es que sea lo más estrecha posible, para un cierto porcentaje de datos contenida en ella, llamado nivel de confianza [78].

Para la determinación del intervalo de confianza, se redefine la representación del modelo difuso $f^{TS}(x_p(t))$ presentado en (2.17) y (2.19), de forma matricial como:

$$\hat{y}(t) = f^{TS}(x_p(t)) = \sum_{r=1}^{N_r} h_r(x_p(t)) \cdot x^T(t)\theta_r = \sum_{r=1}^{N_r} \psi_r^T(x_p(t))\theta_r \quad (2.55)$$

$$\hat{y}(t) = \Psi^T(x_p(t))\Theta \quad (2.56)$$

Con:

$$\psi_r^T(x_p(t)) = h_r(x_p(t)) \cdot x^T(t) \quad (2.57)$$

$$\Psi^T(x_p(t)) = [\psi_1^T(x_p(t)), \dots, \psi_{N_r}^T(x_p(t))] \quad (2.58)$$

$$\Theta = [\theta_1, \dots, \theta_{N_r}] \quad (2.59)$$

Donde $h_r(x_p(t))$, presentado en (2.16), denota el grado de activación de la r-ésima regla; N_r es la cantidad de reglas, $x_p(t)$ y $x(t)$ son el vector de las premisas y de las consecuencias del modelo respectivamente; θ_r es el vector de parámetros de la r-ésima regla; Ψ^T es la matriz de regresión difusa; y Θ es la matriz de coeficientes para todo el set de reglas.

Es importante notar que, en el caso de la modelación lineal, también es posible caracterizar la incertidumbre mediante el presente método. En este caso, en la expresión (2.55), $N_r = 1$ y $h_r(x_p(t)) = 1$ para todo instante t .

El error $e(t)$ entre los valores medidos y la salida del modelo puede ser definido como (2.60).

$$e(t) = y(t) - \Psi^T(x_p(t))\Theta \quad (2.60)$$

Luego, de acuerdo al procedimiento de identificación de modelo indicado en la sección 2.3. , los parámetros en Θ se definen separadamente en cada regla, por lo que se tienen N_r ecuaciones del tipo:

$$e_r(t) = y_r(t) - \psi_r^T(t)\theta_r \quad (2.61)$$

$$e_r = y_r - \psi_r^T\theta_r \quad (2.62)$$

Con:

$$e_r(t) = h_r(x_p(t))e(t) \quad (2.63)$$

$$y_r(t) = h_r(x_p(t))y(t) \quad (2.64)$$

$$\psi_r^T(t) = h_r(x_p(t))x^T(t) \quad (2.65)$$

Donde $y(t)$ y $x(t)$ son los datos de la salida y de las premisas del modelo respectivamente en el instante t . A su vez, se tiene:

$$y_r = [y_r(1), \dots, y_r(N)]^T \quad (2.66)$$

$$\psi_r^T = [\psi_r(1), \dots, \psi_r(N)]^T \quad (2.67)$$

Con N correspondiente a la cantidad de datos en el conjunto de entrenamiento.

La covarianza esperada de la diferencia entre los datos observados en el conjunto de validación y la salida del r -ésimo modelo local está dada por (2.68).

$$(\Delta\hat{y}_r)^2 = cov(y_r - \hat{y}_r) = \hat{\sigma}_r^2 I + \hat{\sigma}_r^2 \psi_r^T (\psi_r \psi_r^T)^{-1} \psi_r \quad (2.68)$$

Con:

$$\hat{y}_r = x^T(t)\hat{\theta}_r \quad (2.69)$$

$$\hat{\sigma}_r^2 I = \mathbb{E}\{e_r e_r^T\} \quad (2.70)$$

Donde y_r son los datos “observados” por la r -ésima regla; \hat{y}_r es la salida de cada sistema local, donde $\hat{\theta}_r$ son los parámetros estimados de las consecuencias del modelo a partir mediante el proceso mencionado en la sección 2.3.5. ; $cov(\cdot)$ es el operador covarianza; σ_r es la varianza del modelo local.

Luego, los intervalos de confianza inferior y superior para cada modelo local r , es definido como (2.71) y (2.72) respectivamente.

$$\underline{f}_r(x_p(t)) = \psi_r^T(t)\theta_r - \alpha\Delta\hat{y}_r(t) \quad (2.71)$$

$$\bar{f}_r(x_p(t)) = \psi_r^T(t)\theta_r + \alpha\Delta\hat{y}_r(t) \quad (2.72)$$

Con:

$$\Delta\hat{y}_r(t) = \hat{\sigma}_r\sqrt{1 - \psi_r^T(t)(\psi_r\psi_r^T)^{-1}\psi_r(t)} \quad (2.73)$$

Donde α debe ser sintonizado dependiendo de la cantidad de datos que se quiera contener dentro de la banda definida por los intervalos. Finalmente, el intervalo inferior y superior para un instante t queda representado como (2.74) y (2.75) respectivamente.

$$\underline{\hat{y}}(t) = f^{TS}(x_p(t)) - \alpha I^{TS}(x_p(t)) \quad (2.74)$$

$$\bar{\hat{y}}(t) = f^{TS}(x_p(t)) + \alpha I^{TS}(x_p(t)) \quad (2.75)$$

Siendo el intervalo de confianza $I^{TS}(x_p(t))$ definido en (2.76).

$$I^{TS}(x_p(t)) = \sum_{r=1}^{N_r} h_r(x_p(t))\Delta\hat{y}_r(t) \quad (2.76)$$

2.5.3. Índices de evaluación de intervalos.

De acuerdo a lo expuesto anteriormente, el objetivo de estos modelos de intervalos es obtener una función superior y una función inferior lo más estrecho posible, mientras que la banda generada por estas dos funciones contenga la mayor cantidad posible de datos medidos. Para evaluar este requerimiento se proponen dos indicadores de desempeño, que deben ser empleados en el conjunto de datos destinado a validación. El primero, llamado “Probabilidad de Confianza” (CP por sus siglas en inglés) se define en (2.77).

$$CP = \frac{1}{N} \sum_{t=1}^N \delta_t \quad (2.77)$$

Donde N es la cantidad de datos y δ_t es una variable binaria que es “1” si el dato $y(t)$ está contenido en el intervalo en el instante t , y es “0” en caso contrario.

El segundo indicador, llamado “Ancho Promedio Normalizado” (NAW por sus siglas en inglés) es definido en (2.78).

$$NAW = \frac{1}{(y_{max} - y_{min})} \cdot \frac{1}{N} \sum_{t=1}^N \left(\bar{\hat{y}}(t) - \underline{\hat{y}}(t) \right) \quad (2.78)$$

Donde N es la cantidad de datos, y_{max} e y_{min} son los valores máximos y mínimos medidos, e $\bar{\hat{y}}(t)$ e $\underline{\hat{y}}(t)$ son el intervalo superior e intervalo inferior del modelo.

Es posible que, en algunos casos no se disponga del registro necesario y suficiente para realizar el proceso de identificación de modelos, como es en general la disponibilidad de datos de demanda eléctrica. Para resolver este problema, se propone una metodología basada principalmente en los algoritmos de “*Self-Organizing Map*” descrito en la sección 2.6. y de Cadenas de Markov descrito en la sección 2.7.

2.6. Self-Organizing Map.

La siguiente sección presenta el algoritmo de clasificación empleado para agrupar los hogares del caso de estudio en función de su información socio-demográfica, cuyos resultados son presentados en la sección 3.6.1.

2.6.1. Definición.

En esta sección se describen los Mapas Auto-Organizados (SOM por sus siglas en inglés) desarrollados por Kohonen [79], [80]. Una de las principales características de SOM de Kohonen es su capacidad para clasificar conjuntos complejos de patrones de forma no supervisada, mediante la extracción de criterios de clasificación de los datos, que luego son utilizados y expresados en una manera no explícita [81]. Esta clasificación se lleva a cabo mediante el uso de la distribución de un espacio de entrada V_i , sobre un espacio de salida V_o (por lo general de una dimensión inferior), definido por un conjunto de neuronas generalmente distribuidas sobre una línea o un plano, de forma rectangular o hexagonal, y la preservación de las propiedades topológicas de los patrones en el espacio de entrada.

La característica más importante de SOM es la posibilidad de comparar *clusters* que resumen los datos. La red auto-organizada, representada en la Figura 2.9, debe extraer los patrones, regularidades, correlaciones, categorías o características importantes de cada observación y asignarla a un *cluster*. Cada *cluster* es proyectado a un nodo del mapa de salida, por lo que la comparación de las proyecciones derivadas de diferentes observaciones permite estimar la proximidad entre sus respectivos *clusters*, dado que observaciones similares se proyectan en el mismo nodo. Por otro lado, la disimilitud aumenta con la distancia que separa las dos proyecciones. De este modo, el espacio de *cluster* se identifica con el mapa, por lo que las proyecciones permiten

interpretar al mismo tiempo el espacio de *cluster* (salida) y el espacio de observación (entrada) [82].

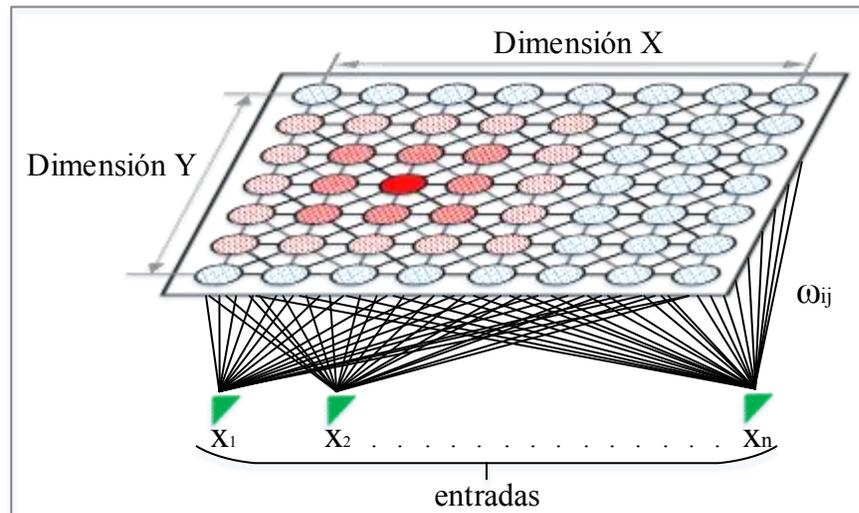


Figura 2.9: Diagrama de entradas y salidas de SOM.

2.6.2. Proceso de entrenamiento.

El algoritmo de entrenamiento básico de SOM sigue los siguientes pasos [83]:

1. Se inicializan los pesos de la red, definido para cada neurona j -ésima como $\vec{\omega}_j = (\omega_{j1}, \dots, \omega_{jn})$, con n correspondiente a la cantidad de dimensiones de observación. Dicha inicialización se realiza generalmente de forma aleatoria, aunque también se puede realizar con otros métodos como la elección de entradas al azar.
2. Se considera un vector de entrada $\vec{x} = (x_1, \dots, x_n)$,
3. Se encuentra la neurona activa, cuyos pesos son más cercanos (en el sentido de distancia euclidiana), para el vector \vec{x} , tal como se representa en la Figura 2.10.

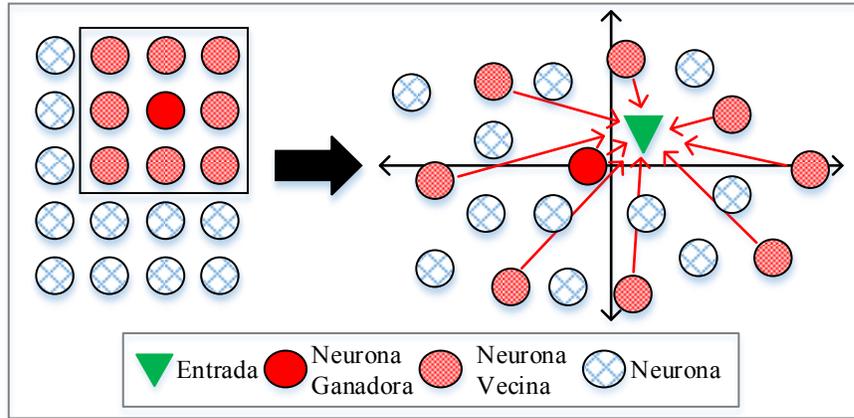


Figura 2.10: Proceso de entrenamiento SOM.

4. Los vectores de ponderación de la neurona activa y los de sus neuronas vecinas se modifican usando la ecuación (2.79).

$$\vec{\omega}_j(t+1) = \vec{\omega}_j(t) + l_r(t)h_{jv}(\vec{x} - \vec{\omega}_j(t)) \quad (2.79)$$

Donde \vec{x} es el vector de entrada, $\vec{\omega}_j$ es el vector de pesos de la neurona j -ésima, y $h_{jv}(\cdot)$ es una función de vecindad.

El tamaño de la vecindad y de la tasa de aprendizaje se actualizan continuamente, por lo general utilizando la función $l_r(t)$, que cambia dinámicamente durante el proceso de aprendizaje de acuerdo con la expresión (2.80).

$$l_r(t) = \frac{l_{r0}}{\left(1 + \frac{c \cdot t}{n_n}\right)} \quad (2.80)$$

Donde l_{r0} es una tasa de aprendizaje inicial, c es una constante de aprendizaje (por lo general igual a 0.2), t es la iteración temporal actual y n_n es el número de neuronas de la red.

5. Se repite el procedimiento desde el paso 2, con nuevos vectores de entrada \vec{x} , hasta completar la cantidad de iteraciones determinadas.

Después del proceso de aprendizaje, un vector de entrada $\vec{x} = (x_1, \dots, x_n)$ activará la neurona j del espacio de salida si el vector de pesos $\vec{\omega}_j = (\omega_{j1}, \dots, \omega_{jn})$ tiene la menor distancia al vector de entrada \vec{x} . De esta manera, cada neurona $\vec{\omega}_j$ corresponde a un vector prototipo (promedio) de la región de espacio de entrada cuyos vectores activan la neurona j , como se puede observar en la representación de la Figura 2.11. Por lo tanto, dos vectores de entradas similares, de acuerdo con

las relaciones definidas en el espacio de entrada V_i , activarán la misma neurona (o dos neuronas diferentes pero cercanas) en el espacio de salida.

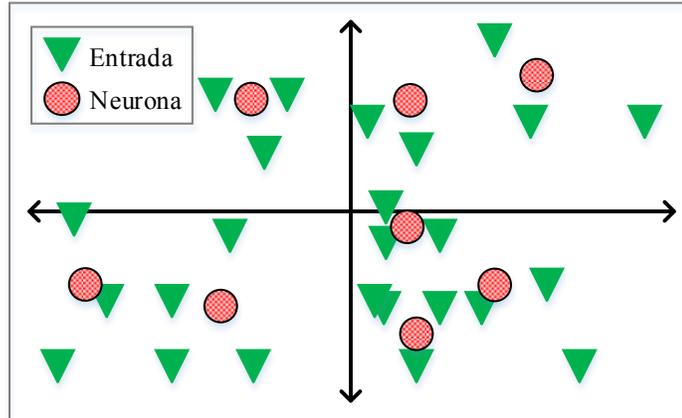


Figura 2.11: SOM entrenado.

Visualizar el SOM por lo general no es directo, debido a que el proceso de clasificación puede llevarse a cabo en espacios de alta dimensión. Uno de los métodos más populares para esto es a través de una matriz de distancias unificada U , que permite una visualización global de las relaciones de proximidad de los vectores de referencia en un SOM [84].

2.7. Generación de perfiles aleatorios.

La siguiente sección presenta la metodología propuesta para generar perfiles aleatorios de data empleada para simular el perfil de carga de cada hogar del caso de estudio, presentado posteriormente en la sección 3.6.2. de tal forma de obtener variabilidad en los datos que permitan la generación de distintos escenarios de consumo.

Para esto, se propone la utilización de cadenas de Markov discretas en los estados y tiempo, definidas a continuación en la sección 2.7.1. Considerando que cada estado representa lo que se quiere simular (en este caso demanda eléctrica), es posible aplicar cadenas de Markov para la generación de perfiles aleatorios que mantengan las características de los datos reales medidos, sin ser necesariamente una replicación de dichas mediciones.

2.7.1. Cadenas de Markov.

Una cadena de Markov finita y discreta consiste en un proceso que se mueve entre elementos de un conjunto finito Ω [85]. Cada uno de estos elementos se conoce como “estado”, cuya representación depende de la aplicación. Considerando un estado inicial i , el siguiente estado al que se desplazará el proceso queda determinada en base a la probabilidad $\mathbb{P}\{i, \cdot\}$. Esta transición

dependerá solamente del estado actual, y será independiente de los estados que haya tomado el proceso anteriormente. A esta propiedad se le denomina “Propiedad de Markov”.

Con esta configuración se tiene una cadena de Markov con espacio de estados Ω y una Matriz de Transición de Estados (MTE) \mathcal{P} . Dicha matriz, cuya estructura para una cadena de m estados es presentada en (2.81), es compuesta por las probabilidades de transición de un estado i a un estado j , representado por p_{ij} . En esta notación, las filas corresponden al estado i en el instante de tiempo actual t , y las columnas corresponden a los posibles estados j en el instante $t + 1$.

$$\mathcal{P} = \begin{bmatrix} p_{11} & \cdots & p_{1m} \\ \vdots & \ddots & \vdots \\ p_{m1} & \cdots & p_{mm} \end{bmatrix} \quad (2.81)$$

La MTE cumple las propiedades (2.82) y (2.83) derivadas de los axiomas de probabilidad, por lo que para cada estado i , necesariamente existen una transición a uno de los estados j .

$$p_{ij} \geq 0 \quad \forall i, j \quad (2.82)$$

$$\sum_{j=1}^m p_{ij} = 1 \quad \forall i \quad (2.83)$$

Los valores de cada probabilidad de transición de estado p_{ij} a partir de data real, se obtiene registrando la cantidad de datos que pertenecen al estado i en el instante t y que además pertenecen al estado j en el tiempo $t + 1$. Dicha cantidad se denota como n_{ij} permitiendo obtener, de acuerdo a [86], el estimador máxima verosimilitud de p_{ij} presentado en (2.84).

$$\hat{p}_{ij} = \frac{n_{ij}}{\sum_{j=1}^m n_{ij}} \quad (2.84)$$

Del mismo modo, 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, obteniendo así la expresión (2.85).

$$\hat{p}_i = \frac{n_i}{\sum_{j=1}^m n_{ij}} \quad (2.85)$$

Donde p_i es la probabilidad de que el estado inicial de la cadena sea el estado i , m es el número de estados y n_i corresponde al número de datos que pertenecen al estado i para dicho tiempo de muestreo inicial de la cadena.

Tanto la estimación de probabilidades de transición de estado \hat{p}_{ij} como la estimación de probabilidades iniciales de estado \hat{p}_i son parte de la metodología de generación de perfiles aleatorios descrito a continuación.

2.7.2. Metodología para generación de perfiles.

El procedimiento para la generación de perfiles aleatorios es mostrado en el diagrama de la Figura 2.12, donde se destaca la importancia de determinar la estructura de las cadenas de Markov, tanto en el número de estados m , como en las probabilidades de transición p_{ij} , para un buen desempeño del simulador.

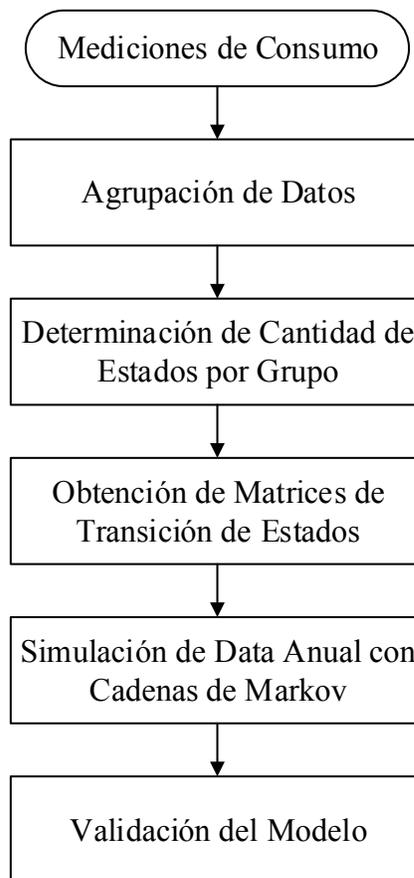


Figura 2.12: Procedimiento para generación de perfiles aleatorios.

Cuando la cantidad de datos con la que se dispone es reducida, existe la posibilidad de no diferenciar los distintos estados que definen la estructura de las cadenas de Markov ($m = 1$). En estos casos el procedimiento comienza con la agrupación de datos que tengan características

similares, es decir, que se encuentren dentro de un mismo rango más reducido de valores y, de esta forma, hacer posible la identificación de más estados. En el presente trabajo, se propone una agrupación en tiempo de muestreo consecutivo, con el fin de contar con transiciones de estado entre muestras consecutivas.

Para realizar la agrupación, se obtienen las características de los datos para cada tiempo de muestreo, que corresponden a sus valores máximos, mínimo y media. Con dichas características y en función del tiempo de muestreo, se determina los rangos temporales (horarios) que tienen características similares entre sí, minimizando las diferencias de valores intragrupos.

El proceso de determinación de grupos comienza con definir el número de grupos s de forma heurística. Luego, se busca minimizar la distancia entre las características de los datos y la media de estas características pertenecientes a un mismo grupo, condición formalizada en las expresiones (2.86) y (2.87).

$$\bar{\mu}_q = \frac{1}{N_q} \sum_{x \in S_q} x \quad (2.86)$$

$$\min_{l_1, \dots, l_s} J = \sum_{q=1}^s \sum_{x \in S_q} \|x - \bar{\mu}_q\|^2 \quad (2.87)$$

En que x corresponde a los datos a agrupar, S_q corresponde al conjunto de datos $q \in \{1, \dots, s\}$, N_q a su cardinalidad y $\bar{\mu}_q$ corresponde a la media de los datos x de conjunto q . Además, S_q cumple la relación (2.88).

$$x \in S_q \Leftrightarrow x \in [l_q, l_{q+1}[\quad (2.88)$$

Donde l_q corresponde a la cota temporal inferior del grupo S_q . Considerando un tiempo de muestreo horario, se tiene que para un día $l_q \in \{0, \dots, 23\}$. Por lo tanto, para el conjunto S_s se tiene la relación (2.89), pues el final de un día es el inicio del día siguiente.

$$x \in S_s \Leftrightarrow x \in [l_s, 23[\cup [0, l_1[\quad (2.89)$$

De esta forma, el procedimiento busca la minimización de la función J de la expresión (2.87), la que es posible realizar mediante algoritmos genéticos, detallado en la sección A.1. del Anexo A, obteniendo así los límites l_q de los conjuntos S_q .

Posteriormente, se utiliza el algoritmo *k-means*, explicado en la sección A.2. del Anexo A, para realizar *clustering* sobre las mediciones de consumo, donde el número de *clusters* corresponde a los estados a utilizar. De esta forma, se tiene la pertenencia de cada dato medido a un estado

definido por el centroide de cada *cluster*, que corresponderá al valor de potencia que tomarán los datos generados por medio de las cadenas de Markov.

El número de estados que compone la cadena se define con el método derivado en [87], donde se determina una cota superior de estados representativos válidos para que la cadena de Markov reproduzca el comportamiento de los datos disponibles, en función de los parámetros de diseño. Este método comienza con la determinación a priori de $r \in [0,1]$ y $p^* \in [0,1]$ deseados, donde p^* indica la máxima probabilidad que se puede aceptar que el estimador de máxima verosimilitud (2.84) varíe en r respecto a su valor real. De esta manera, es necesario verificar que para cada estado se cumpla la desigualdad (2.90).

$$\mathbb{P}\{|\hat{p}_{ij} - p_{ij}| \geq r\} \leq p^* \quad (2.90)$$

Se define n_i en la expresión (2.91) como el número de transiciones que se dan a partir del estado i a cualquiera de los estados $j \in \{1, \dots, m\}$ estados.

$$n_i = \sum_{j=1}^m n_{ij} \quad (2.91)$$

Dichas transiciones desde un estado i a un estado j pueden ser descritas por una secuencia de variables aleatorias $\{X_k, k \in \mathbb{N}\}$, cada una de ellas correspondientes a un experimento de Bernoulli que toma el valor 1 con probabilidad p_{ij} si la transición es efectivamente hacia el estado j , y 0 con probabilidad $(1 - p_{ij})$ si la transición se efectúa hacia un estado distinto de j . De esta forma, se tiene la cota superior (2.92) para la función de probabilidad (2.90).

$$\mathbb{P}\{|\hat{p}_{ij} - p_{ij}| \geq r\} \leq 2e^{-2n_i r^2} \quad (2.92)$$

Por otro lado, la expresión de la varianza de estas variables aleatorias corresponde a (2.93).

$$\text{Var}\{X_k\} = p_{ij}(1 - p_{ij}) \quad (2.93)$$

Dado que $p_{ij} \in [0,1]$, el máximo valor para la expresión (2.93) corresponde a $1/4$ y se obtiene cuando $p_{ij} = 1/2$. De esta forma es posible obtener una nueva cota superior representada por la desigualdad (2.94).

$$\mathbb{P}\{|\hat{p}_{ij} - p_{ij}| \geq r\} \leq \frac{1}{4n_i r^2} \quad (2.94)$$

Considerando además que, por axioma de probabilidad, (2.90) debe ser menor o igual 1, se tiene que la cota superior general, dado r y n_i es (2.95).

$$c(n_i) = \min \left\{ 1, 2e^{-2n_i r^2}, \frac{1}{4n_i r^2} \right\} \quad (2.95)$$

De esta forma, para cumplir los requerimientos de diseño, es necesario satisfacer (2.96) para cada uno de los i estados de partida de la MTE.

$$c(n_i) \leq p^* \quad \forall i \in [1, \dots, m] \quad (2.96)$$

Esto se realiza mediante un proceso iterativo que parte con una alta cantidad de estados, que se va reduciendo hasta que se cumpla la condición (2.96), obteniendo así la cantidad máxima de estados m^* para la cadena de Markov.

Una vez definido la agrupación S_q de los datos a simular, junto con los estados m_q para cada uno de los q grupos de datos, se prosigue con la determinación de las MTE (2.97) compuesto por los estimadores de máxima verosimilitud definidos en (2.84).

$$P_q = \begin{bmatrix} \hat{p}_{11} & \hat{p}_{12} & \cdots & \hat{p}_{1m_q} \\ \hat{p}_{21} & \hat{p}_{22} & \cdots & \hat{p}_{2m_q} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{p}_{m_q 1} & \hat{p}_{m_q 2} & \cdots & \hat{p}_{m_q m_q} \end{bmatrix} \quad (2.97)$$

Teniendo la cadena con sus estados m_q y probabilidades de transición representadas en las MTE P_q asociadas, es posible efectuar una realización para la generación de datos en cada grupo de datos, a través del siguiente proceso:

1. Dividir el intervalo real $[0,1]$ en m_q divisiones, cada uno de largo correspondiente a la probabilidad \hat{p}_{ij} de la MTE del grupo de datos q . Cada una de dichas probabilidades tendrá asociado un estado.
2. Efectuar una realización de una variable aleatoria con distribución uniforme en el intervalo real $[0,1]$.
3. Asociar el valor obtenido de la realización de la variable aleatoria al estado correspondiente. Dicho estado será al cual se producirá la transición.

La Figura 2.13 ejemplifica la propuesta presentada, en que se tienen s cadenas de Markov (grupos de datos), cada una válida dentro de un rango de tiempo determinado, y que generan datos de

potencia. Cada cadena es independiente de las otras, por lo tanto, los datos generados por las s cadenas se deben concatenar para obtener la serie temporal completa de datos.

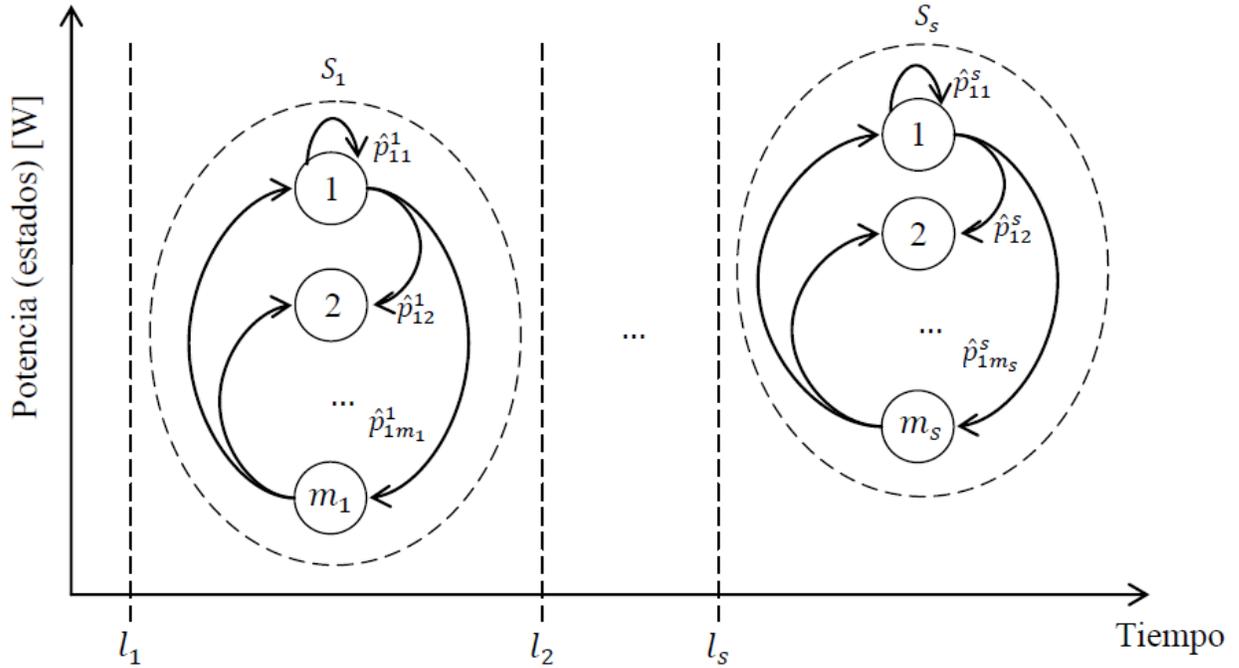


Figura 2.13: Esquema de generación de datos con cadenas de Markov [88].

Finalmente, y como medida de verificación de los modelos generados, se compara el error medio absoluto normalizado (NMAE) de la expresión (2.98) entre las medias de los datos medidos y de los datos reales.

$$NMAE[\%] = \frac{1}{T} \sum_{t=0}^T \left| \frac{\bar{\hat{y}}(t) - \bar{y}(t)}{\bar{y}(t)} \right| \cdot 100[\%] \quad (2.98)$$

Donde $\bar{y}(t)$ e $\bar{\hat{y}}(t)$ son las medias de datos medidos y los datos generados para el instante t respectivamente; y T corresponde al largo de la serie temporal, en este caso igual a 23 (un día).

De esta forma es posible obtener cadenas de Markov que permitan la generación de perfiles de consumo por hogar y, consecuentemente obtener un comportamiento representativo del consumo comunitario, sobre la cual sea posible identificar modelos y caracterizar su incertidumbre asociada para el diseño del sistema de Micro-red.

2.8. Discusión.

En este capítulo se ha realizado una revisión bibliográfica en micro-redes, dando énfasis en el procedimiento para abordar la planificación y diseño de estos sistemas, que tal como se describe en la sección 2.1.3. no existe un método universal. Diversos autores han dedicado su trabajo en la caracterización de la incertidumbre de los recursos renovables y de la demanda eléctrica, sin embargo, no son muchos los estudios que han incluido dicha caracterización en la planificación de una micro-red, cuya influencia es relevante en sistemas energéticos de pequeña escala.

Este trabajo aborda la incertidumbre asociada a dichas variables mediante las técnicas de identificación de sistemas, cuyos aspectos fundamentales han sido descritos dando énfasis al procedimiento para la obtención de modelos difusos de T&S, que permiten la caracterización de procesos no-lineales; y de modelos de intervalos mediante el método de la covarianza, que permiten representar la incertidumbre para la probabilidad de cobertura deseada. A su vez, se ha presentado concepto de análisis de estabilidad de sistemas, que garantiza la correcta operación del modelo diseñado.

Se presenta el algoritmo de redes neuronales SOM, para la clasificación de individuos en función de sus características y patrones, que junto con el procedimiento descrito basado en cadenas de Markov, son parte de una metodología para la simulación de un perfil de consumo característico que represente el consumo real cuando no se disponga de su registro.

Capítulo 3. Caracterización de los recursos renovables y demanda eléctrica.

3.1. Caso de Estudio: Comunidad de José Painecura Hueñalihuen.

La comunidad indígena Mapuche de José Painecura Hueñalihuen, se encuentra inserta en la localidad de Hueñalihuen en las coordenadas geográficas 38.54° S; 73.50° O, ubicada en la comuna de Carahue, IX Región de la Araucanía, Chile, a 45 [km] del pueblo de Carahue y a 100 [km] de la ciudad de Temuco, capital de la Región (ver Figura 3.1). El sector norte de la comunidad limita con la localidad de Hueñalihuen Alto, y el sector sur con Coi-Coi y Bajo Yupehue. En su extremo oeste, la comunidad limita con el Océano Pacífico.

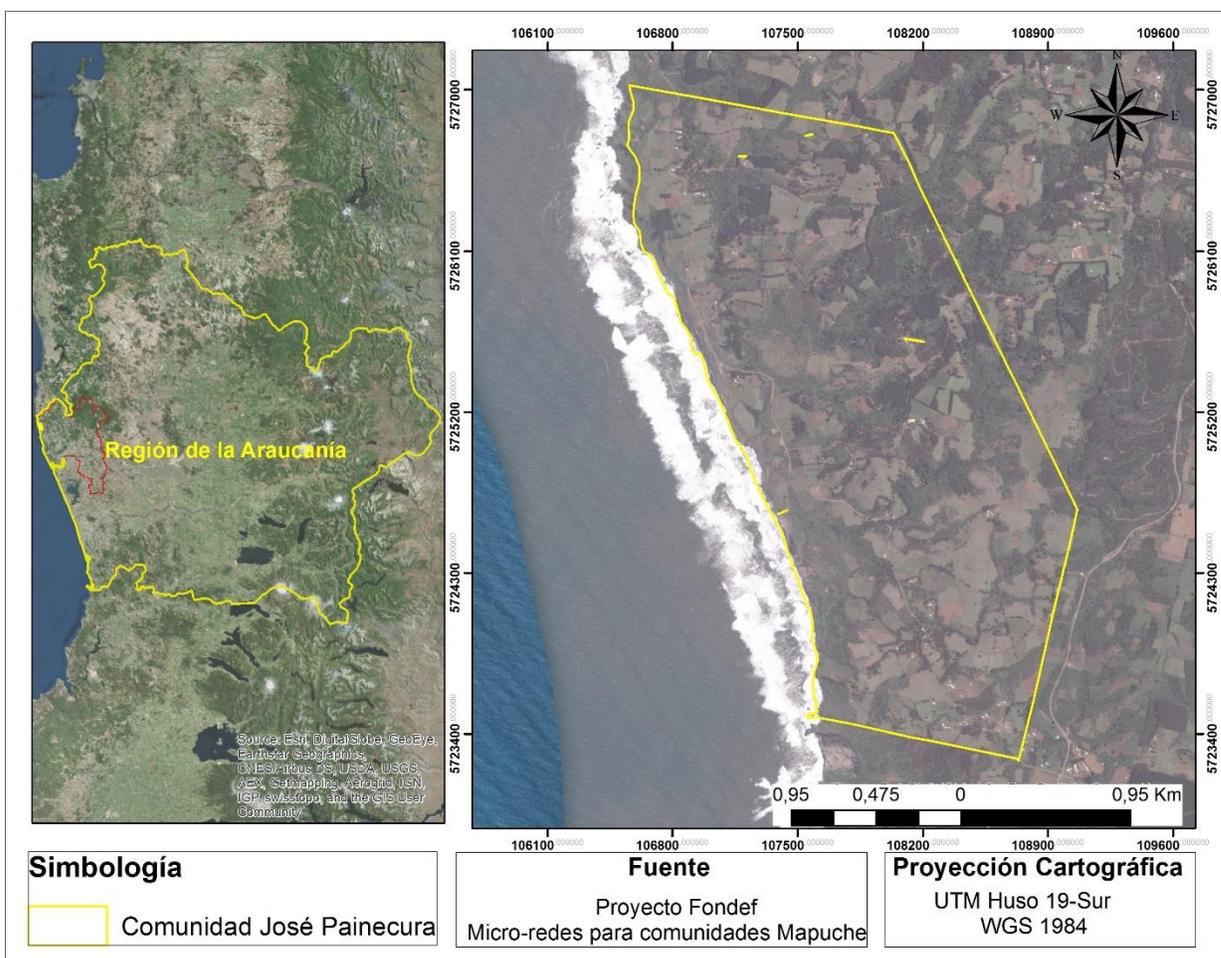


Figura 3.1: Ubicación geográfica de la comunidad de José Painecura Hueñalihuen [89].

Mediante información obtenida en terreno por el equipo de trabajo del proyecto FONDEF IDeA ID14I10063 (2015-2016), se determinó que la localidad se encuentra en un terreno costero de

515.47 [Ha] de extensión, conformado por montes y quebradas. Cuenta con acceso limitado debido al mal estado de los caminos (de ripio y tierra), transporte público restringido a un par de veces al día y la cobertura de telefonía fija, celular e internet no existe. La distancia mínima entre viviendas es de 20 [m], mientras que la máxima es de 786 [m]. La comunidad está conformada por 44 familias, cuya principal actividad económica consiste en la siembra de trigo, avena, papas y porotos; la crianza porcina y de aves de corral; y recolección de algas, como el cochayuyo.

La comunidad se ha hecho partícipe del proyecto FONDEF a tal punto que forman parte activa del mismo, puesto que su compromiso ha permitido obtener la información necesaria para su desarrollo a través del trabajo en el contexto del modelo participativo presentado en [90]. Actualmente, la comunidad se encuentra conectada a la red eléctrica principal, sin embargo, el costo actual de la energía corresponde a una de las tarifas más altas de Chile, alcanzando un valor superior al 65% de la tarifa aplicada a un cliente residencial de Santiago, lo que impacta considerablemente en el presupuesto familiar, cuyos ingresos reducidos no provienen de un sueldo fijo.

La calidad del servicio es deficiente, con lo cual es común encontrar problemas como fenómenos de parpadeo de la tensión y cortes recurrentes. Lo anterior afecta en gran medida a la comunidad, puesto que los problemas se presentan constantemente, con cortes eléctricos que tienen una duración aproximada de dos días o incluso una semana. Las interrupciones no programadas del servicio eléctrico, no sólo generan los problemas típicos como pérdida de conservación de los alimentos, sino que también desabastecimiento de agua, pues su principal método de obtención consiste en extracción en pozos o vertientes mediante moto-bomba eléctrica.

Las condiciones locales relacionadas con el medio físico donde en que se encuentra la comunidad en estudio son descritas en detalle a continuación.

3.2. Condiciones climáticas y geográficas.

Las condiciones climáticas de la localidad donde se encuentra inmersa la comunidad de José Painecura Hueñalihuen son estimadas mediante la información recopilada en el periodo 1961-1990 por la estación meteorológica de Puerto Saavedra, ubicada a 30 [km] de la zona de estudio

El clima de la localidad, definido como las condiciones y fenómenos atmosféricos esperados de una determinada zona [91], es clasificada como un clima templado lluvioso cálido sin estación seca de acuerdo al sistema de W. Köppen [92], es decir, posee las siguientes características atmosféricas:

- La temperatura mes del mes más frío es inferior a 18 [°C] y superior a -3 [°C], mientras que en el mes más cálido es inferior a 22 [°C] y, en al menos cuatro meses, existen temperaturas medias que superan los 10 [°C].
- El monto de precipitación del mes más lluvioso está comprendido entre 3 y 10 veces la precipitación del mes más seco.

Dichas características se observan en la información climática obtenida por la estación y presentada en el diagrama climático de la Figura 3.2, donde se tienen los datos promedios de temperatura y

precipitación. El mes más frío corresponde a junio, mientras que el mes más cálido es enero. Por otro lado, el mes más lluvioso es mayo, mientras que el mes más seco es febrero.

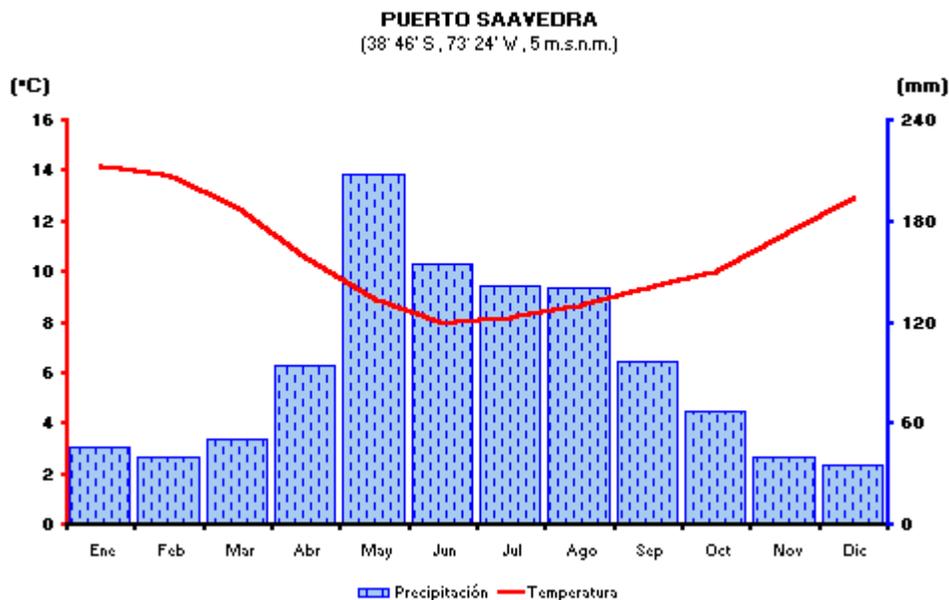


Figura 3.2: Diagrama climático - Estación meteorológica de Puerto Saavedra [92].

Considerando el régimen hídrico de la zona, se observa una precipitación media anual de 1260 [mm] y un periodo seco de cuatro a cinco meses en la época estival. Además, debido a que la localidad se encuentra en una zona con influencia marina, la variación de las temperaturas medias es menor con respecto al interior del continente, presentándose veranos frescos e inviernos apacible [93]. Por otro lado, dicha influencia marina otorga un alto componente salino en el ambiente presente de estas zonas.

En la Figura 3.3 se presentan las regiones del mundo en donde existen condiciones climáticas similares a la localidad de estudio, correspondiente principalmente a zonas de Europa atlántica y central, las costas de Norteamérica septentrional, Sudamérica suroriental, las costas orientales de China y Australia, y Nueva Zelanda.

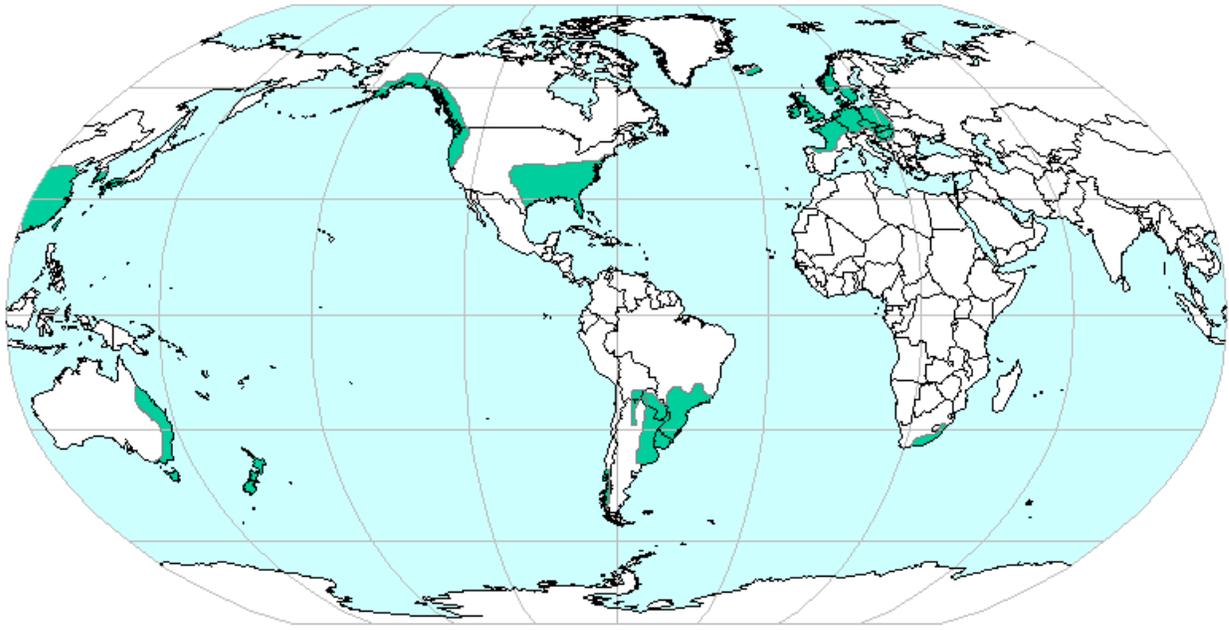


Figura 3.3: Regiones del mundo con clima templado lluvioso [92].

Una implicancia directa en las condiciones climáticas presentes en la localidad corresponde a la cobertura vegetal, correspondientes a superficie de bosque nativo y de plantación de pino y de eucalipto, que ocupan gran parte del terreno disponible en la comunidad, con una altura promedio estimada de 10 [m].

Con respecto a las condiciones geográficas de la localidad, la comunidad de José Painecura Hueñalihuen se encuentra ubicada en un terreno costero, por lo que gran parte de su superficie se encuentra aproximadamente al nivel del mar, sin embargo, debido a que la zona se encuentra aledaña al límite sur del cordón montañoso denominado Cordillera de Nahuelbuta, la localidad se caracteriza también por poseer áreas en torno a los 200 [m.s.n.m] y pendientes que oscilan entre el 10% y 100% (5° a 45° aproximadamente). En la Figura 3.4(a) se presenta el mapa de alturas de la superficie determinada por los límites de la comunidad, mientras que en la Figura 3.4(b) se presenta el mapa de pendientes de dicha superficie.

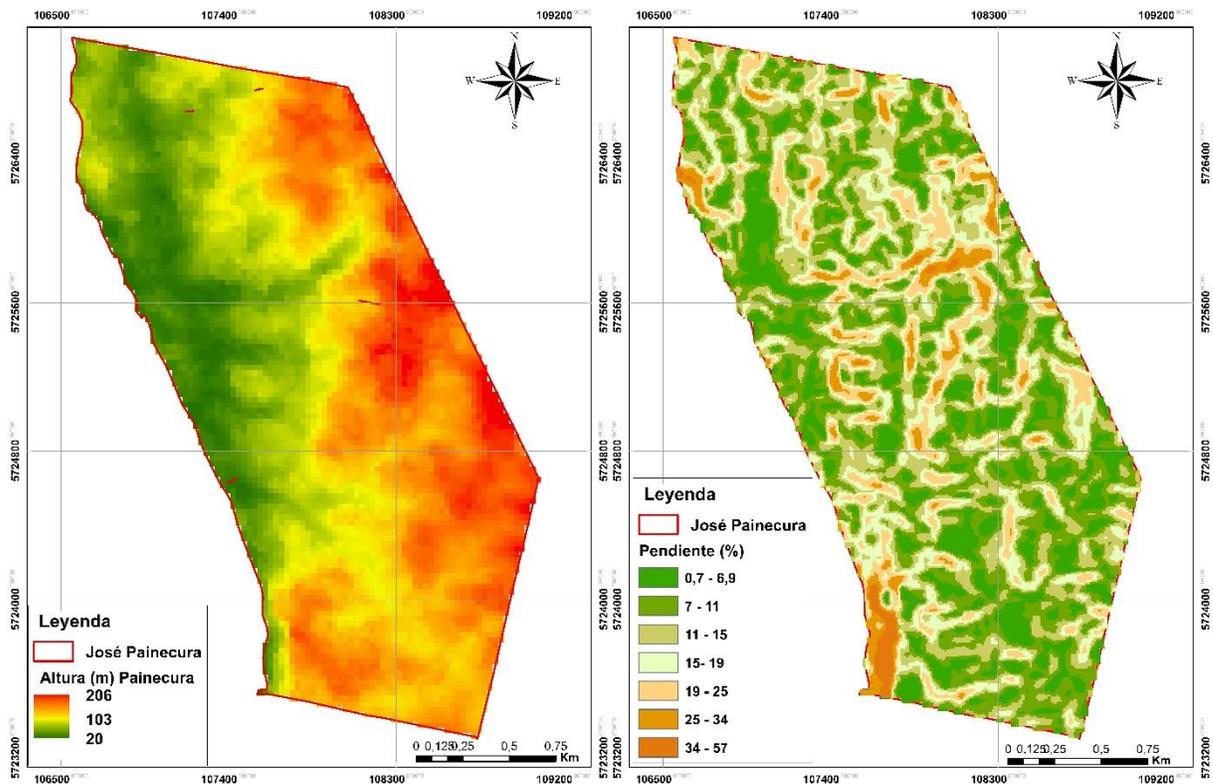


Figura 3.4: Condiciones geográficas de la comunidad de José Paineicura Hueñalihuen. (a) Mapa de alturas; (b) Mapa de pendientes.

De esta forma, se tiene así un terreno costero principalmente escarpado conformado por montes, bosques y quebradas, y consecuentemente, distintas condiciones locales de generación mediante recursos energéticos renovables, que hay que considerar al momento de determinar el lugar de la instalación de las distintas unidades de generación.

Estas condiciones climáticas y geográficas descritas determinan la disponibilidad y potencial energético de los recursos renovables solar y eólicos presentadas a continuación, además de las limitaciones físicas y espaciales a las que estarán sujetos los distintos componentes de la micro-red.

3.3. Recursos energéticos.

El proceso de planificación de una micro-red se inicia con la realización un estudio de caracterización del recurso eólico y del recurso solar existente en la localidad, con la finalidad de determinar el potencial energético de la zona, y estimar así la cantidad de consumo que será posible abastecer mediante estas fuentes de energía. Para estimar dichos recursos, se cuenta con mediciones empíricas de estas variables meteorológicas, las que son completadas con la información simulada

de los modelos de mesoescala (Explorador de Energía Eólica¹ y Explorador de Energía Solar²) del Departamento de Geofísica de la Universidad de Chile, para obtener un perfil eólico y un perfil solar anual.

3.3.1. Recurso eólico.

Para la obtención de perfil eólico anual, es necesario determinar previamente la zona de la localidad en estudio en que se disponga del mayor potencial energético que, en el caso de la generación eólica, es dependiente de las condiciones geográficas. Para ello, haciendo uso de los recursos SIG³ (Sistema de Información Geográfica) disponibles en el Explorador de Energía Eólica, se ha representado en la Figura 3.5 los promedios anuales con 1 [km] de resolución espacial de la velocidad del viento a 20 [m] de altura y del factor de planta de un aerogenerador estándar a 10 [m] de altura de capacidad entre 0 [kW] a 10 [kW].

Basado en esta información, se define la ubicación de estación meteorológica en las coordenadas 38° 32' 12.26'' S, 73° 30' 8.78'' O (indicado con el punto rojo en la Figura 3.5), donde se obtiene una de las mejores condiciones del recurso eólico. En este punto, el registro de datos de velocidad del viento promedio registrado por la estación es tomado a 5 [m] de altura, extrapoliéndolos a 15 [m], considerando que está es la altura aproximada de un aerogenerador empleado para generación a pequeña escala. El registro horario contempla un periodo de 292 días, que inicia el 4 de julio del 2015 y finaliza el 21 de abril del 2016, completando la información con la base de datos del Explorador de Energía Eólica, para obtener así el registro de un año completo.

La Figura 3.6 presenta el ciclo anual de la velocidad del viento obtenida. A través de estos resultados, se tiene que su promedio es de 4.87 [m/s]. Aproximadamente el 75% del tiempo se alcanzan velocidades por sobre los 3 [m/s], que corresponde a la velocidad típica que permite a un aerogenerador romper la inercia de sus aspas. Por otro lado, existe una probabilidad menor al 5% de que el recurso eólico alcance velocidades por sobre los 12 [m/s], condiciones que son seguras para estas tecnologías.

¹ Herramienta de análisis del recurso viento, que entrega resultados de simulación numérica de las condiciones de viento y densidad del aire, de manera gráfica y cómoda para el usuario. Estas simulaciones son realizadas por el modelo WRF (Weather Research and Forecasting), un modelo avanzado, ampliamente utilizado para analizar el recurso eólico en el mundo. La información entregada por el Explorador Eólico permite realizar una evaluación preliminar del recurso eólico en un determinado lugar. <<http://walker.dgf.uchile.cl/Explorador/Eolico2/>>

² Herramienta de análisis de la radiación solar superficial, que entrega resultados de manera gráfica y cómoda para el usuario. La metodología utilizada para generar esta base de datos se basa en el uso de un modelo de transferencia radiativa combinado con información de nubosidad inferida del satélite GOES EAST y observaciones locales. La información entregada por el Explorador Solar permite realizar una evaluación preliminar del recurso solar en un determinado lugar de gran parte del territorio nacional. <<http://walker.dgf.uchile.cl/Explorador/Solar3/>>

³ Conjunto de herramientas y base de datos que permite a un usuario crear consultas interactivas, integrar, analizar y representar de una intuitiva la información geográfica referenciada asociada a un territorio, conectando mapas con bases de datos.

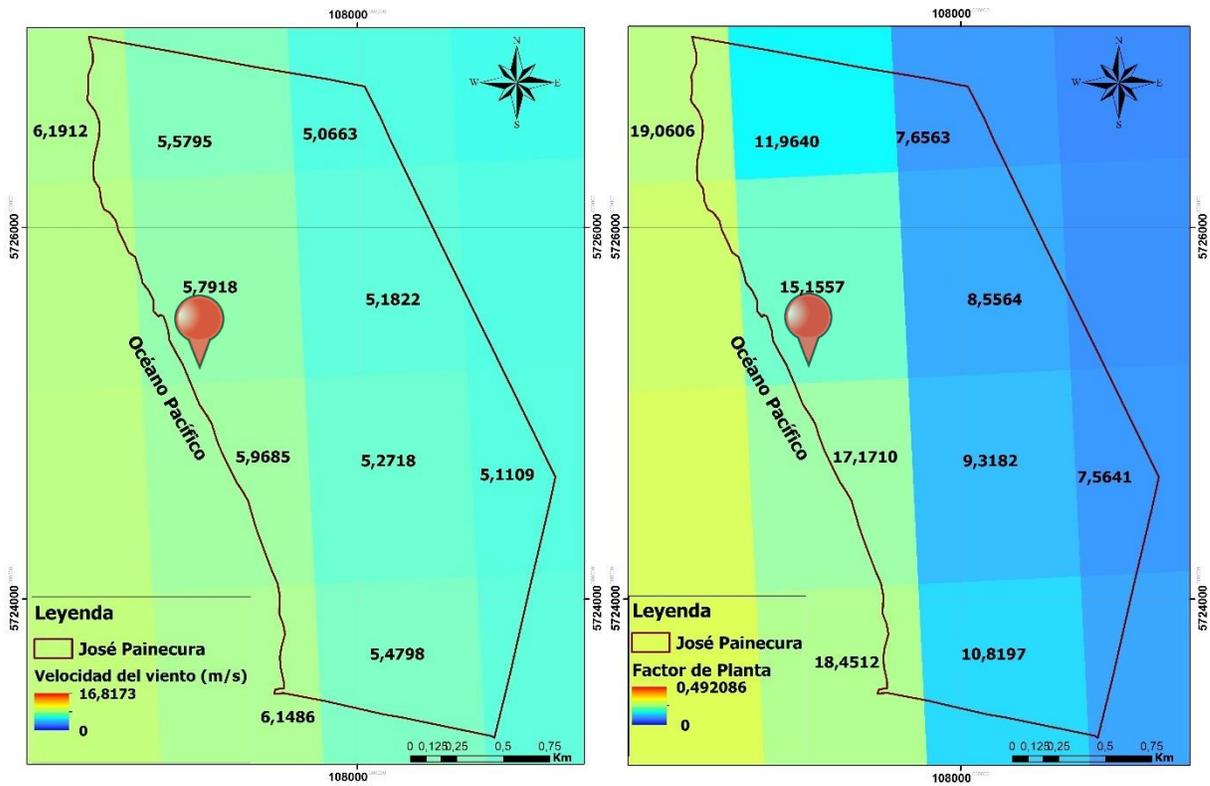


Figura 3.5: Potencial eólico en José Paineicura Hueñalihuen.

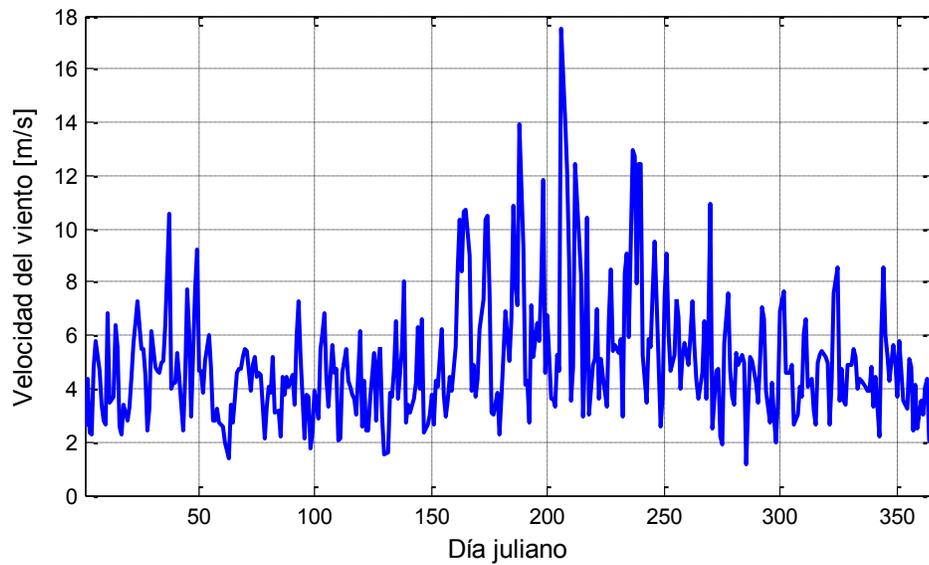


Figura 3.6: Velocidad promedio del viento en José Paineicura Hueñalihuen.

Por último, existe una fuerte dependencia estacional, ya que existe una mayor disponibilidad del recurso en los meses de invierno, los que a la vez coinciden con los meses de menor radiación solar, tal como se describe a continuación.

3.3.2. Recurso solar.

Empleando los recursos SIG disponibles en el Explorador de Energía Solar, se ha representado en la Figura 3.7 los promedios anuales con 1 [km] de resolución espacial de la radiación global horizontal y el factor de planta de un arreglo fotovoltaico estándar fijo orientado hacia el norte e inclinado según la latitud geográfica. En este caso, es posible observar que el recurso solar es aproximadamente independiente de las condiciones geográficas del lugar, obteniendo una radiación promedio en torno a los 4.5 [kW/m² día] y un factor de planta por sobre el 16% en toda superficie de la localidad en estudio.

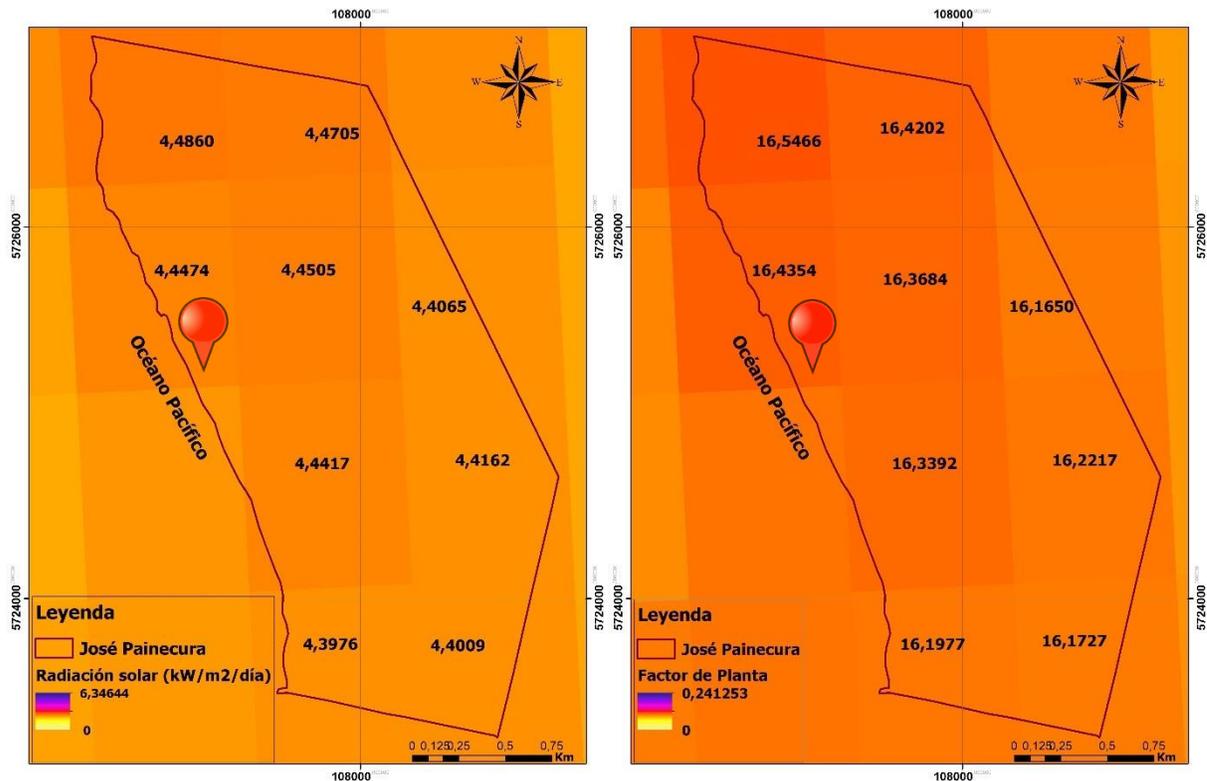


Figura 3.7: Potencial solar en José Painecura Hueñalihuen.

Al igual que para el recurso eólico, la estación meteorológica permite el registro horario de radiación solar horizontal en el mismo punto geográfico, cubriendo un periodo de 292 días continuos, que inicia el 4 de julio del 2015 y finaliza el 21 de abril del 2016, información que es completada con la base de datos del Explorador de Energía Solar para obtener un año completo de registro. La Figura 3.8 presenta la insolación diaria para todo el año, donde se tiene que en verano se alcanza una insolación diaria cercana a los 8 [kWh/m²], mientras que en invierno en general no se supera los 2 [kWh/m²]. El promedio anual de insolación es de 4.30 [kWh/m²] y se presenta una fuerte dependencia estacional, producto de la lejanía del Sol en los meses de invierno y de la mayor presencia de nubosidad.

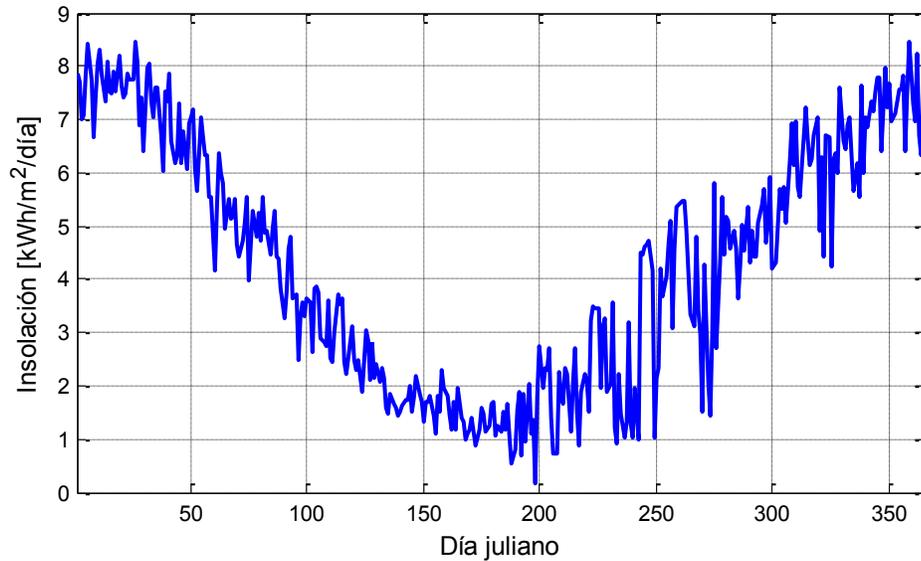


Figura 3.8: Insolación diaria en José Painecura Huenalihuen.

Con el registro anual de la velocidad del viento y radiación solar, es posible caracterizar su comportamiento a través de los modelos empíricos descritos en el Capítulo 2. obteniendo así los resultados presentados a continuación en las secciones 3.4. y 3.5. respectivamente.

3.4. Modelo del recurso eólico.

A continuación, se presentan el proceso de identificación descrito en la sección 2.3. para el modelamiento de la velocidad del viento, seleccionando la estructura para cada modelo, junto con sus parámetros estimados y analizando su estabilidad. Posteriormente, el mejor modelo es empleado para la caracterización de la incertidumbre mediante la identificación de modelos de intervalos descrito en la sección 2.5. para distintos niveles de confianza. Los resultados son evaluados a 1 paso (una hora) y a 24 pasos (un día) de predicción.

3.4.1. Modelación lineal y modelación difusa de Takagi-Sugeno.

Los datos disponibles para realizar el proceso de identificación de modelos del recurso eólico corresponden a una serie de tiempo obtenido de la forma presentada en la sección 3.3.1. Estos datos comprenden el periodo de un año completo con una tasa de muestreo de 1 [hr], el cual es dividido en los siguientes conjuntos:

- **Entrenamiento (60%):** 1 de enero al 6 de agosto;
- **Test (20%):** 7 de agosto al 18 de octubre;

- **Validación (20%):** 19 de octubre al 31 de diciembre.

Considerando una cantidad máxima de 25 auto-regresores, se tiene que el modelo lineal AR identificado es el presentado en la expresión (3.1). Observando los parámetros del modelo, es posible notar que la predicción dada para el instante t corresponde básicamente a continuar la tendencia en el instante $t - 1$, con un leve ajuste en función de los instantes anteriores. Debido a la alta incertidumbre que posee el recurso eólico, se justifica que el modelo obtenido posea esta característica.

$$\begin{aligned} \hat{y}_{lineal}(t) = & 0.9904y(t - 1) - 0.0880y(t - 2) + 0.0624y(t - 3) \\ & - 0.0598y(t - 4) + 0.0390y(t - 6) - 0.0270y(t - 7) \\ & - 0.0194y(t - 10) - 0.0203y(t - 14) + 0.0301y(t - 17) \\ & + 0.0252y(t - 21) + 0.0805y(t - 23) - 0.0832y(t - 25) \\ & + 0.3435 \end{aligned} \quad (3.1)$$

De acuerdo al procedimiento de la sección 2.4. cuyos resultados son presentados en la Tabla A.1 de la sección B.1. del Anexo B, el modelo lineal identificado en (3.1) es globalmente estable según Lyapunov.

Empleando los mismos conjuntos de datos, considerando una cantidad máxima de 25 auto-regresores y 6 reglas, se tiene que el modelo difuso de T&S identificado es conformado por 2 reglas, cuyas premisas se muestran en la Figura 3.9 y en la Tabla A.4 de la sección B.2. del Anexo B, mientras los parámetros de sus consecuencias son presentadas en la base de reglas de la expresión (3.2). Por el lado de las premisas, se observa la identificación dos reglas claramente diferenciadas: una regla centrada en 0 [m/s] activada para bajas velocidades de viento, y una regla centrada en aproximadamente 16 [m/s] que se activa en velocidades más altas. Ambas reglas poseen una alta desviación estándar, debido a la incertidumbre del recurso eólico ya mencionado. Los parámetros de las consecuencias del modelo difuso poseen una tendencia similar al modelo lineal antes identificado debido al mismo fenómeno.

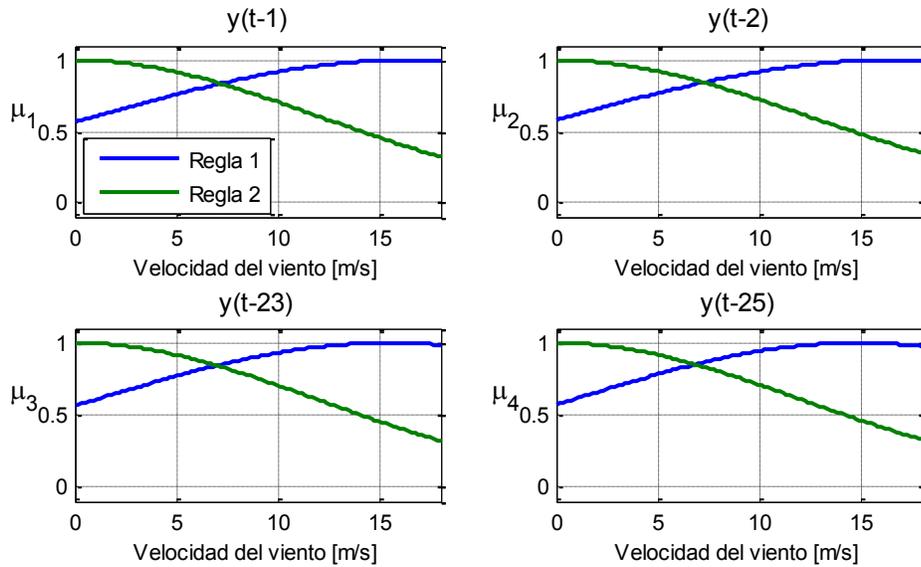


Figura 3.9: Funciones de pertenencia del recurso eólico.

$R^1 : Si$

$y(t-1)$ es MF_1^1 y $y(t-2)$ es MF_2^1 y $y(t-23)$ es MF_3^1 y $y(t-25)$ es MF_4^1

entonces

$$y_1(t) = 0.9988y(t-1) - 0.1314y(t-2) + 0.0852y(t-23) - 0.1666y(t-25) + 2.2367$$

(3.2)

$R^2 : Si$

$y(t-1)$ es MF_1^2 y $y(t-2)$ es MF_2^2 y $y(t-23)$ es MF_3^2 y $y(t-25)$ es MF_4^2

entonces

$$y_2(t) = 0.9357y(t-1) - 0.1053y(t-2) + 0.0781y(t-23) - 0.0820y(t-25) + 0.2448$$

De acuerdo al procedimiento de la sección 2.4. cuyos resultados son presentados en la Tabla A.1 de la sección B.1 del Anexo B, el modelo difuso identificado es globalmente estable según Lyapunov.

El desempeño en el conjunto de validación a 24 pasos del modelo lineal y modelo difuso de T&S identificados se muestra a continuación en la Figura 3.10 para 120 horas (5 días). La Tabla 3.1 y la Tabla 3.2 presentan el RMSE y MAE de ambos modelos en los tres conjuntos de datos para 1 paso y 24 pasos de predicción.

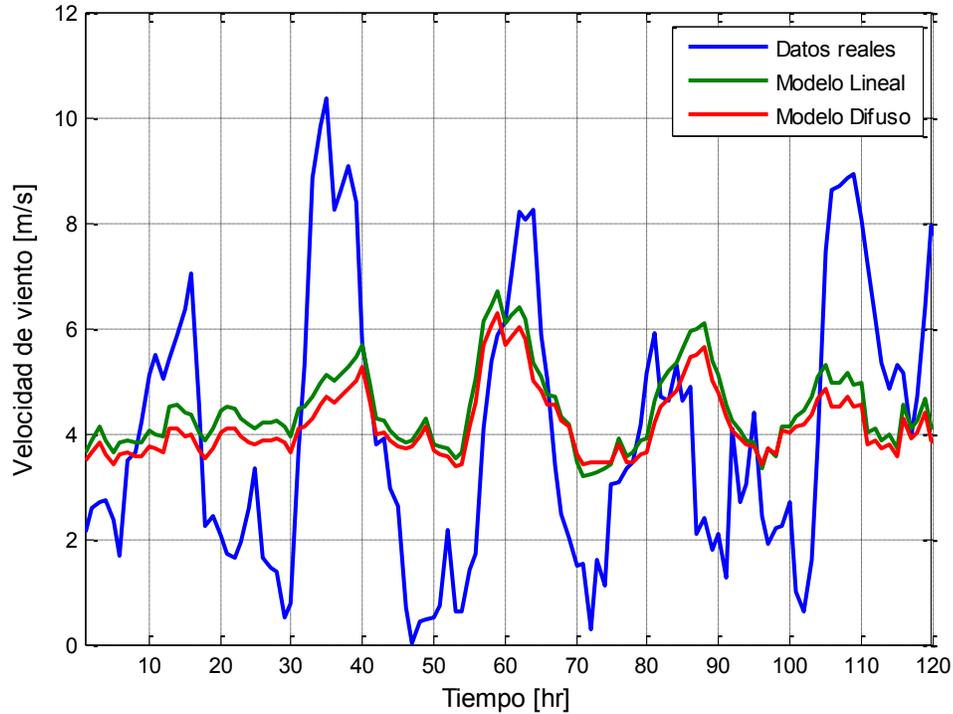


Figura 3.10: Desempeño de los modelos del recurso eólico a 24 pasos.

Tabla 3.1: Medidas de error de los modelos del recurso eólico a 1 paso.

Conjunto	RMSE lineal [m/s]	RMSE difuso [m/s]	MAE lineal [m/s]	MAE difuso [m/s]
Entrenamiento	1.0839	1.0887	0.7698	0.7705
Test	1.1557	1.1539	0.8559	0.8539
Validación	1.0067	1.0092	0.7543	0.7551

Tabla 3.2: Medidas de error de los modelos del recurso eólico a 24 pasos.

Conjunto	RMSE lineal [m/s]	RMSE difuso [m/s]	MAE lineal [m/s]	MAE difuso [m/s]
Entrenamiento	2.7698	2.7967	2.1048	2.1033
Test	2.8128	2.8518	2.2369	2.2456
Validación	2.4638	2.4938	1.9995	2.0006

De acuerdo a los resultados obtenidos, se aprecia que ambos modelos identificados poseen un desempeño similar, especialmente a 1 paso de predicción, donde casi no existe diferenciación entre ambos. Debido a la alta incertidumbre del recurso eólico en la Figura 3.10 se tiene que ambos modelos aproximan su predicción a 24 horas a la media de los datos medidos, cercano a los 4 [m/s], generando un error de predicción por sobre 2 [m/s] de ambas métricas en casi todos los conjuntos de datos.

Finalmente, se opta por escoger el modelo lineal AR identificado para generar intervalos de confianza. Este modelo posee una estructura más simple que el modelo difuso de T&S y su desempeño es comparable.

3.4.2. Inclusión de incertidumbre mediante intervalo de confianza.

La caracterización de la incertidumbre del recurso eólico es determinada mediante el método de la covarianza presentado en la sección 2.5.2. para distintos niveles de confianza que van desde el 10% al 90%. Los resultados obtenidos en el conjunto de datos de validación a 1 paso y a 24 pasos se muestran a continuación en las Figura 3.11 y Figura 3.12, respectivamente para 120 horas (5 días). Su desempeño en el conjunto de validación, representados por los índices CP y NAW definidos en las expresiones (2.77) y (2.78) respectivamente, se presenta en la Tabla 3.3.

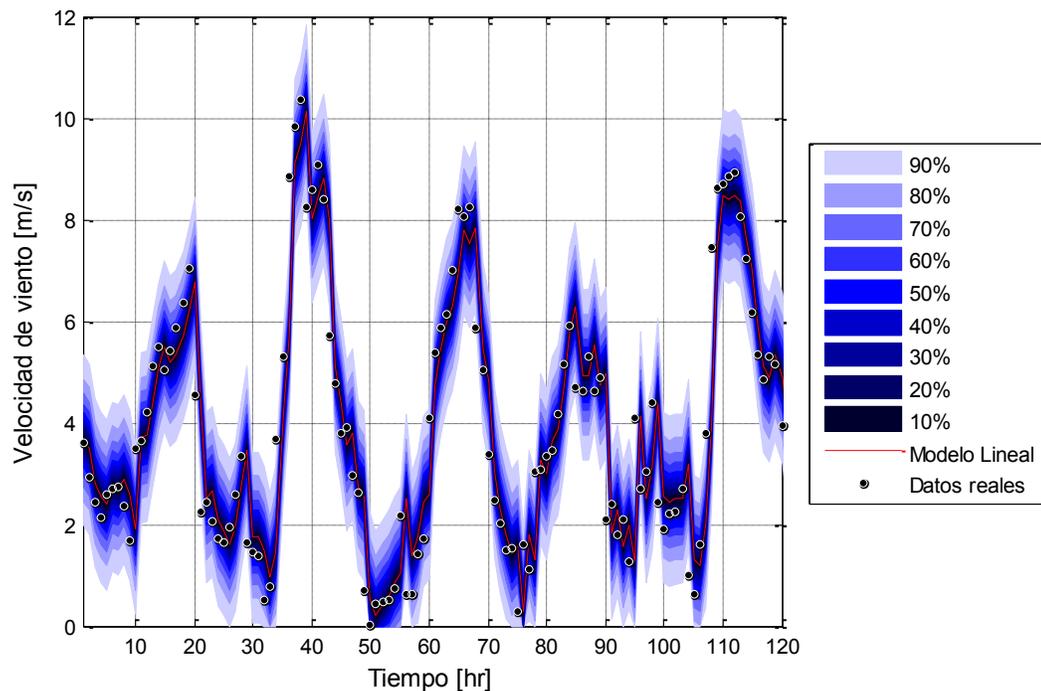


Figura 3.11: Intervalos lineales del recurso eólico a 1 paso.

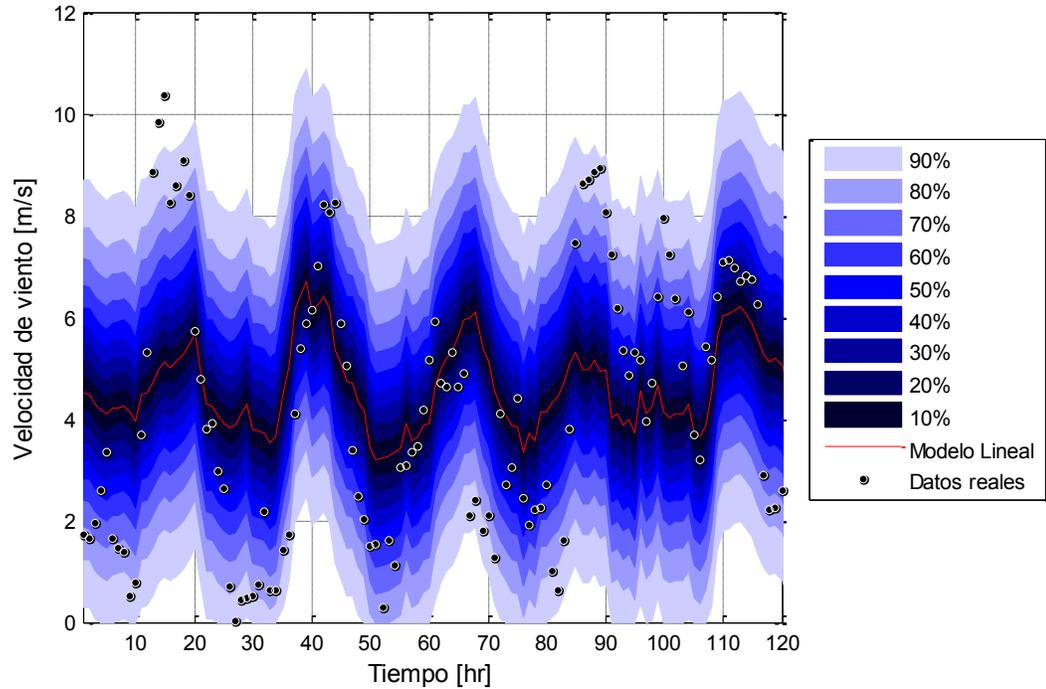


Figura 3.12: Intervalos lineales del recurso eólico a 24 pasos.

Tabla 3.3: Desempeño de los modelos de intervalos lineales del recurso eólico.

Nivel de Confianza	CP 1 paso	NAW 1 paso	CP 24 pasos	NAW 24 pasos
10%	8.92%	1.45%	10.21%	4.77%
20%	18.59%	3.02%	19.37%	9.62%
30%	28.14%	4.61%	29.34%	14.42%
40%	38.16%	6.27%	38.97%	19.35%
50%	46.44%	8.00%	48.59%	24.69%
60%	58.43%	10.42%	58.69%	31.05%
70%	70.82%	13.50%	69.13%	38.83%
80%	81.76%	17.55%	80.75%	48.04%
90%	90.10%	24.36%	92.19%	61.33%

Como se aprecia en las Figura 3.11 y Figura 3.12, los intervalos generados cubren la mayor parte de los datos medidos. De acuerdo a lo presentado en la Tabla 3.3, los modelos de intervalos se encuentran correctamente identificados, pues su probabilidad de confianza (CP) se encuentra en torno al nivel de confianza sintonizado. Finalmente, a través de estos modelos es posible capturar

la incertidumbre del recurso eólico, sin embargo, para ello se debe contar con intervalos de ancho considerable dependiendo del nivel de confianza y pasos de predicción que se desee.

3.5. Modelo del recurso solar.

En esta sección se presentan el proceso de identificación descrito en la sección 2.3. para el modelamiento de la radiación global horizontal, seleccionando la estructura para cada modelo, junto con sus parámetros estimados y analizando su estabilidad. Luego, el mejor modelo es empleado para la caracterización de la incertidumbre mediante la identificación de modelos de intervalos descrito en la sección 2.5. para distintos niveles de confianza.

En ambos procesos se ha incluido un post-procesamiento de datos, dado por el conocimiento previo del fenómeno a modelar. Considerando que durante las horas de noche no tiene sentido seguir la referencia de un ajuste matemático, este post-procesamiento de datos consiste en imponer el valor de 0 [kW/m²] como salida de dichos modelos (lineales, difusos de T&S e intervalos) si no se supera un umbral mínimo de 0.006 [kW/m²] medidos para ese instante. Los resultados obtenidos son evaluados a 1 paso (una hora) y a 24 pasos (un día) de predicción.

3.5.1. Modelación lineal y modelación difusa de Takagi-Sugeno.

Los datos disponibles para realizar el proceso de identificación de modelos del recurso solar corresponden a una serie de tiempo obtenido de la forma presentada en la sección 3.3.2. Estos datos comprenden el periodo de un año completo con una tasa de muestreo de 1 [hr], el cual, al igual que el recurso eólico, es dividido en los siguientes conjuntos:

- **Entrenamiento (60%):** 1 de enero al 6 de agosto;
- **Test (20%):** 7 de agosto al 18 de octubre;
- **Validación (20%):** 19 de octubre al 31 de diciembre.

Considerando una cantidad máxima de 25 auto-regresores, se tiene que el modelo lineal AR identificado es el presentado en la expresión (3.3). Analizando los parámetros del modelo obtenido, se observa que la predicción dada para el instante t depende principalmente de los primeros auto-regresores, pero también (en menor medida) de los últimos. Esto indica que un buen modelo de radiación requiere información del día anterior.

$$\begin{aligned}
 \hat{y}_{lineal}(t) = & 1.0094y(t-1) - 0.1340y(t-2) - 0.0032y(t-3) \\
 & - 0.0271y(t-5) - 0.0345y(t-6) + 0.0358y(t-10) \\
 & - 0.0422y(t-15) + 0.0391y(t-19) - 0.0322y(t-20) \\
 & + 0.0864y(t-21) + 0.1127y(t-23) + 0.1869y(t-24) \\
 & - 0.1944y(t-25) + 0.0042
 \end{aligned} \tag{3.3}$$

De acuerdo al procedimiento de la sección 2.4. cuyos resultados son presentados en la Tabla A.2 de la sección B.1. del Anexo B, el modelo lineal identificado en (3.3) es globalmente estable según Lyapunov.

Empleando los mismos conjuntos de datos, se ha considerado una cantidad máxima de 25 auto-regresores y 6 reglas para la identificación del modelo difuso de T&S. Siguiendo el procedimiento de la sección 2.4. no se obtiene ningún modelo globalmente estable según Lyapunov. Sin embargo, a continuación, se presenta el mejor modelo identificado, cuyos resultados en el análisis de estabilidad se presenta en detalle en la Tabla A.2 de la sección B.1. del Anexo B.

El modelo presentado se conforma por 2 reglas, cuyas premisas se muestran en la Figura 3.13 y en la Tabla A.5 de la sección B.2. del Anexo B, mientras que los parámetros de sus consecuencias son presentados en la base de reglas de la expresión (3.4). Dicho modelo posee solo 3 polos inestables $\{1.0003, 0.9637 + j0.2771, 0.9637 - j0.2771\}$ de un total de 75, los cuales corresponden al modelo local de la primera regla. Se estima que esta condición puede mejorar al emplear otro conjunto de datos de radiación en el proceso de identificación.

Por el lado de las premisas, se observa dos reglas claramente diferenciadas, exceptuando las regresiones $y(t - 6)$ e $y(t - 18)$. Se tiene además que, la mayoría de estas auto-regresiones representan dos condiciones de operación: una centrada aproximadamente en $0.5 \text{ [kW/m}^2\text{]}$ con una desviación estándar cercana a los $0.4 \text{ [kW/m}^2\text{]}$, y otra centrada en $0 \text{ [kW/m}^2\text{]}$ con una mayor concentración de datos, dada por una desviación en torno a los $0.01 \text{ [kW/m}^2\text{]}$ a $0.02 \text{ [kW/m}^2\text{]}$. Este resultado en la identificación del modelo es consecuencia de la diferencia de condiciones de radiación que existe entre el día y la noche.

Con respecto a los parámetros de las consecuencias del modelo difuso, es posible notar que la primera regla pondera en mayor medida las primeras auto-regresiones, por lo que es corresponde a un modelo local que toma más en cuenta las condiciones actuales de radiación. Por otro lado, la segunda regla posee una mayor ponderación en las últimas auto-regresiones, por lo que este modelo local considera también las condiciones de radiación del día anterior.

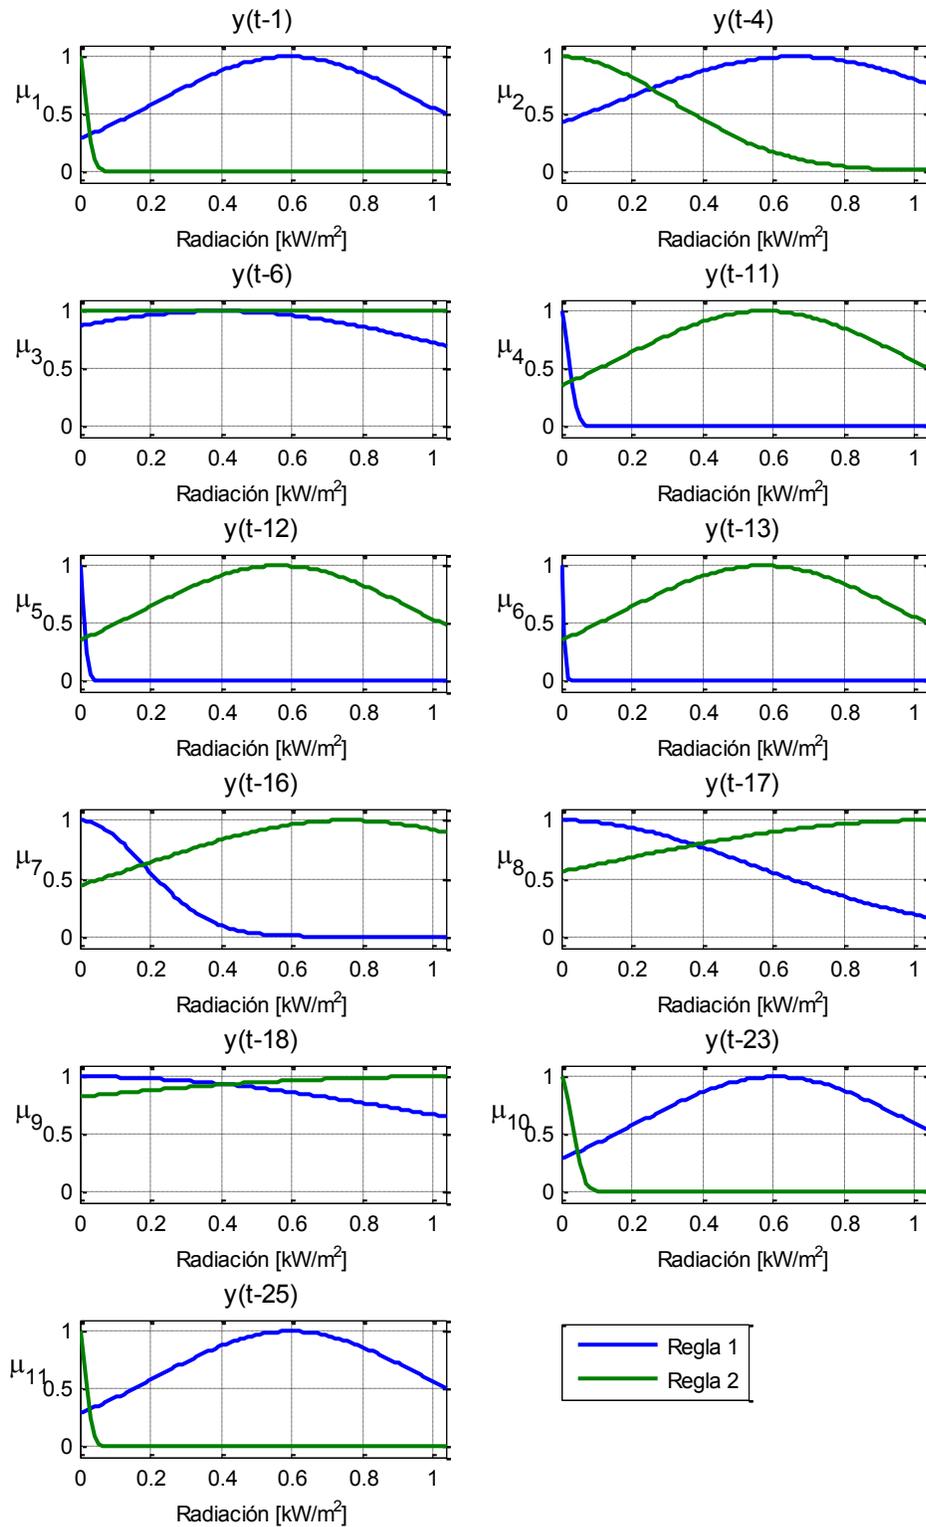


Figura 3.13: Funciones de pertenencia del recurso solar.

$R^1 : Si$

$y(t-1)$ es MF_1^1 y $y(y-4)$ es MF_2^1 y $y(t-6)$ es MF_3^1 y $y(t-11)$ es MF_4^1 y
 $y(t-12)$ es MF_5^1 y $y(y-13)$ es MF_6^1 y $y(t-16)$ es MF_7^1 y
 $y(t-17)$ es MF_8^1 y $y(t-18)$ es MF_9^1 y $y(y-23)$ es MF_{10}^1 y $y(t-25)$ es MF_{11}^1

entonces

$$\begin{aligned} y_1(t) = & 0.9314y(t-1) - 0.0833y(t-4) - 0.1027y(t-6) + 0.1174y(t-11) \\ & - 0.1475y(t-12) + 0.0876y(t-13) - 0.0032y(t-16) \\ & - 0.1021y(t-17) + 0.1820y(t-18) + 0.1944y(t-23) \\ & - 0.0726y(t-25) + 0.0082 \end{aligned} \tag{3.4}$$

$R^2 : Si$

$y(t-1)$ es MF_1^2 y $y(y-4)$ es MF_2^2 y $y(t-6)$ es MF_3^2 y $y(t-11)$ es MF_4^2 y
 $y(t-12)$ es MF_5^2 y $y(y-13)$ es MF_6^2 y $y(t-16)$ es MF_7^2 y
 $y(t-17)$ es MF_8^2 y $y(t-18)$ es MF_9^2 y $y(y-23)$ es MF_{10}^2 y $y(t-25)$ es MF_{11}^2

entonces

$$\begin{aligned} y_1(t) = & 0.6608y(t-1) - 0.0570y(t-4) + 0.0176y(t-6) + 0.0018y(t-11) \\ & - 0.0113y(t-12) + 0.0086y(t-13) - 0.0008y(t-16) \\ & + 0.0004y(t-17) - 0.0086y(t-18) + 0.3413y(t-23) \\ & - 0.1546y(t-25) + 0.0005 \end{aligned}$$

El desempeño en el conjunto de validación a 24 pasos del modelo lineal y modelo difuso de T&S identificados se muestra a continuación en la Figura 3.14 para 120 horas (5 días). La Tabla 3.4 y la Tabla 3.5 presentan el RMSE y MAE de ambos modelos en los tres conjuntos de datos para 1 paso y 24 pasos de predicción.

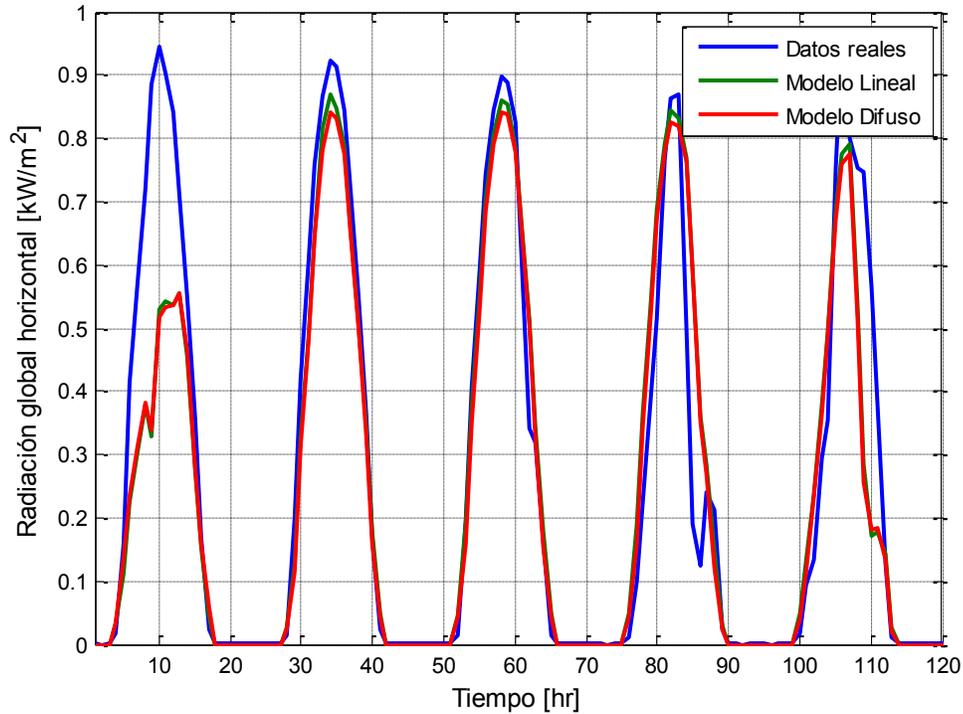


Figura 3.14: Desempeño de los modelos del recurso solar a 24 pasos.

Tabla 3.4: Medidas de error de los modelos del recurso solar a 1 paso.

Conjunto	RMSE lineal [kW/m ²]	RMSE difuso [kW/m ²]	MAE lineal [kW/m ²]	MAE difuso [kW/m ²]
Entrenamiento	0.049204	0.049649	0.023049	0.023396
Test	0.057257	0.057313	0.026416	0.026647
Validación	0.073961	0.073786	0.039630	0.039965

Tabla 3.5: Medidas de error de los modelos del recurso solar a 24 pasos.

Conjunto	RMSE lineal [kW/m ²]	RMSE difuso [kW/m ²]	MAE lineal [kW/m ²]	MAE difuso [kW/m ²]
Entrenamiento	0.099142	0.099716	0.044602	0.045625
Test	0.114350	0.114210	0.055003	0.053139
Validación	0.169725	0.169519	0.090668	0.091663

De acuerdo a los resultados obtenidos, se deriva que ambos modelos identificados presentan un desempeño similar, notando que, en su evaluación a 1 paso de predicción, el modelo lineal posee un error en torno a 1% menor que el modelo difuso de T&S (a excepción del RMSE del conjunto de validación de datos). Por otro lado, se observa la Figura 3.14, que ambos modelos siguen la tendencia de los datos del día anterior y que subestiman la disponibilidad del recurso solar, especialmente el modelo difuso.

Finalmente, se concluye que ambos modelos caracterizan adecuadamente el comportamiento del recurso solar. Se opta por escoger el modelo lineal AR identificado para generar intervalos de confianza. Este modelo posee una estructura más simple y un mejor desempeño que el modelo difuso de T&S, además de ser estable.

3.5.2. Inclusión de incertidumbre mediante intervalo de confianza.

La caracterización de la incertidumbre del recurso solar, al igual que en recurso eólico, es determinada mediante el método de la covarianza presentado en la sección 2.5.2. para niveles de confianza que van desde el 10% al 90%. Los resultados obtenidos a 1 paso y 24 pasos en el conjunto de validación se muestran a continuación en las Figura 3.15 y Figura 3.16, respectivamente para 120 horas (5 días). Su desempeño en el conjunto de validación, representados por los índices CP y NAW, se presenta en la Tabla 3.6.

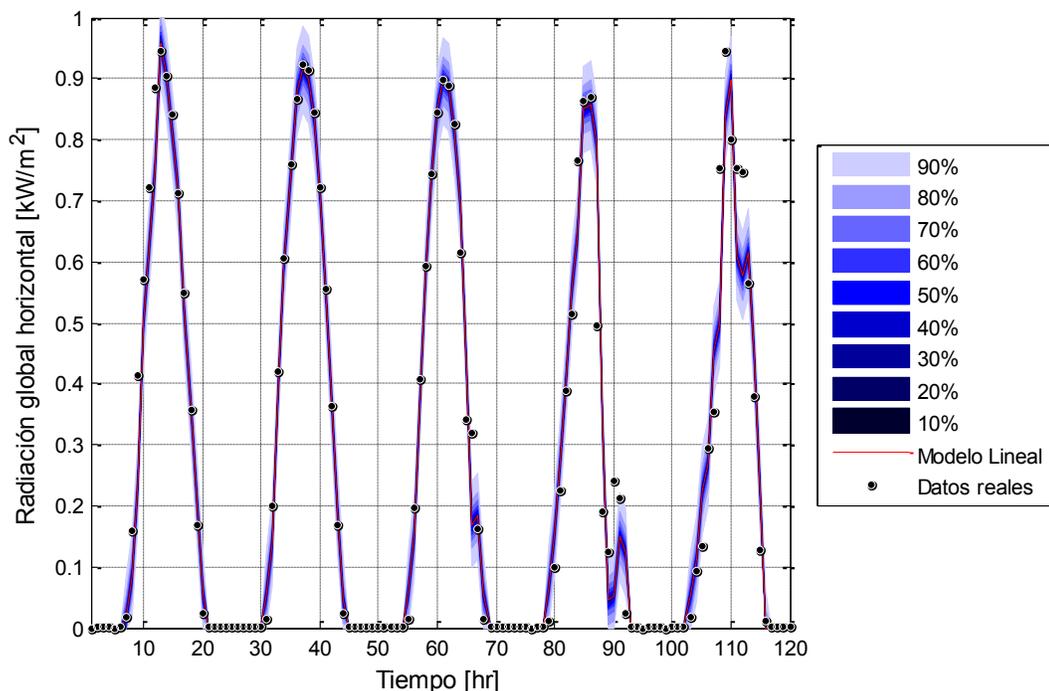


Figura 3.15: Intervalos lineales del recurso solar a 1 paso.

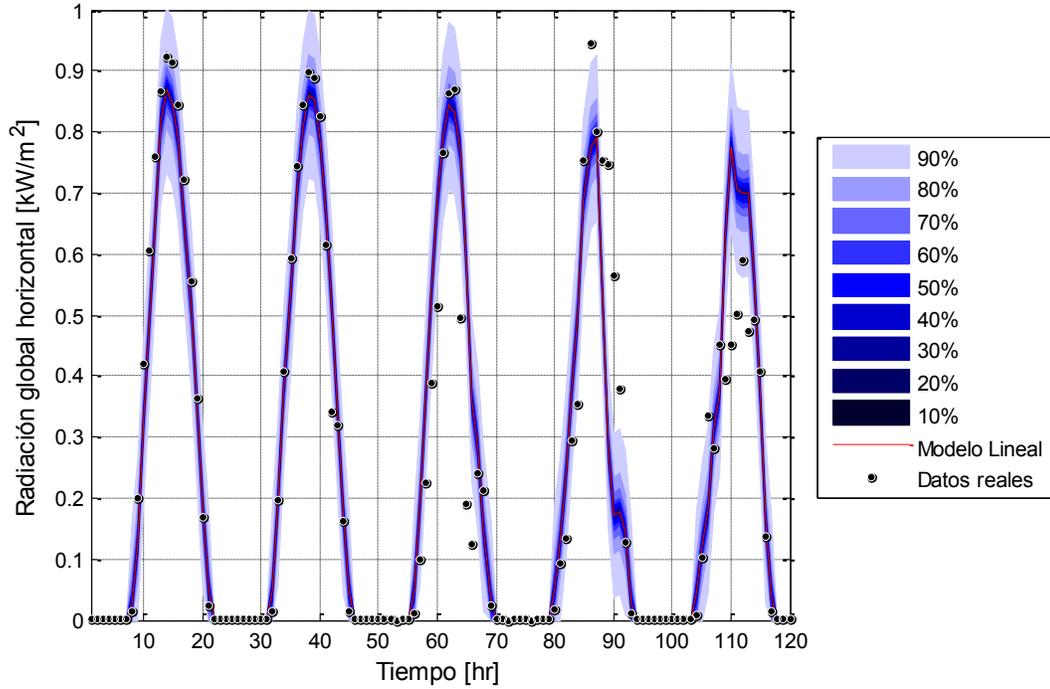


Figura 3.16: Intervalos lineales del recurso solar a 24 pasos.

Tabla 3.6: Desempeño de los modelos de intervalos lineales del recurso solar.

Nivel de Confianza	CP 1 paso	NAW 1 paso	CP 24 pasos	NAW 24 pasos
10%	41.69%	0.01%	40.55%	0.01%
20%	41.69%	0.01%	40.55%	0.01%
30%	43.72%	0.20%	42.14%	0.38%
40%	46.03%	0.58%	44.66%	1.07%
50%	50.43%	1.06%	46.48%	1.73%
60%	55.65%	1.72%	49.41%	2.56%
70%	61.55%	2.74%	54.93%	4.07%
80%	69.37%	4.33%	63.38%	6.88%
90%	80.89%	7.65%	77.76%	14.34%

Como se aprecia en las Figura 3.15 y Figura 3.16, los intervalos generados cubren la mayor parte de los datos medidos. A partir de los resultados presentados en la Tabla 3.6, se tiene que es imposible obtener modelos de intervalos sintonizados a un nivel de confianza menor al 50%, pues debido a post-procesamiento de datos indicado al comienzo de esta sección, durante las horas de

noche el dato medido coincidirá con el intervalo inferior y superior simultáneamente en 0 [kW/m²], generando también un NAW reducido.

Por otro lado, se observa que, para niveles de confianza mayores, no se alcanza la probabilidad de confianza (CP) deseada, efecto que se acentúa mientras mayor sea cantidad de pasos de predicción. Esto se debe a que, dado la fuerte dependencia estacional del recurso solar, los sets de datos de entrenamiento y test (enero a octubre) empleados para identificación de los modelos, no son lo suficientemente representativos para representar el comportamiento del recurso solar en el conjunto de validación (noviembre a diciembre), por lo que se sugiere el empleo un conjunto de datos más extenso si se dispone.

Finalmente, se concluye que a través de estos modelos intervalos es posible capturar la incertidumbre del recurso solar, la cual es reducida y, por lo tanto, fácil de caracterizar.

3.6. Estimación y modelo de demanda eléctrica.

En esta sección se presentan los resultados de estimación de demanda eléctrica para el caso de estudio. Para ello, se procede a clasificar los hogares en función de la información socio-demográfica recopilada mediante encuestas, empleando el algoritmo SOM descrito en la sección 2.6. Luego, con la información de consumo de un representante de cada grupo de hogares clasificados y empleando el método propuesto en la sección 2.7. basado en cadenas de Markov, se simula el perfil residencial. Junto con estimación de demanda eléctrica de espacios comunes se obtiene un set de datos representativos que caracteriza el consumo general de la comunidad.

Posterior a esto, con el set de datos de demanda eléctrica generado, se realiza el proceso de identificación de modelos descrito en la sección 2.3. , seleccionando la estructura para cada modelo, junto con sus parámetros estimados y analizando su estabilidad. Luego, el mejor modelo es empleado para la caracterización de la incertidumbre mediante la identificación de modelos de intervalos descrito en la sección 2.5. para distintos niveles de confianza.

3.6.1. Clasificación de hogares.

El trabajo de clasificación de hogares comienza con la recopilación de información socio-demográfica de cada hogar a través de encuestas. De acuerdo al trabajo realizado por Caquilpan [94] y a la experiencia en terreno, se consideran 3 características por hogar que se encuentran directamente relacionado con el comportamiento de su demanda eléctrica:

- **Miembros:** Richardson et al. [95] y Yamaguchi et al. [96] destacan la relevancia de esta variable en la estimación de la demanda residencial. Existe una relación directa entre el nivel de demanda y la cantidad de personas que componen el hogar, sin embargo, dicha relación no es lineal, debido al uso de electrodomésticos compartidos y a los distintos patrones de comportamiento de cada miembro.

- **Rango etario:** Basado en los estudios de Yamaguchi [96] y en el trabajo realizado por Llanos [97], el patrón de comportamiento de cada miembro del hogar está estrechamente relacionado con su edad. Mientras un adulto mayor permanece gran parte del tiempo al interior de su hogar; un joven tiende a realizar más actividades que lo mantienen fuera del hogar, o bien depender más de los equipos electrónicos que alguien mayor. De acuerdo a esto, se han definido 3 rangos etarios propuestos por Calvo et al. [98] y presentados en la Tabla 3.7.
- **Actividades:** El patrón de comportamiento de cada individuo también depende de la actividad que desarrolla durante el día. El tipo de trabajo (o estudio) se relaciona directamente con el instante y tiempo en que pasan en su hogar [95]. De acuerdo a lo anterior, y basado en la experiencia en terreno se han identificado 5 actividades en la comunidad en estudio, presentadas en la Tabla 3.7.

De esta forma, se definen 9 variables relevantes ligadas a estas 3 características relacionadas con el comportamiento de consumo, presentadas a continuación en la Tabla 3.7.

Tabla 3.7: Variables relevantes para la caracterización de consumo por hogar.

Variable	Característica	Descripción
Nº de integrantes	Miembros	Cantidad de residentes permanentes
Nº de jóvenes	Rango Etario	Cantidad de residentes menores a 18 años
Nº de adultos	Rango Etario	Cantidad de residentes entre 18 y 60 años
Nº de mayores	Rango Etario	Cantidad de residentes mayores a 60 años
Nº de estudiantes	Actividades	Miembros que asisten de manera regular a un establecimiento educacional
Nº de establecidos	Actividades	Miembros con trabajo de jornada laboral completa o similar
Nº de agricultores	Actividades	Miembros dedicados a la agricultura familiar o de subsistencia
Nº de dueñas de casa	Actividades	Miembros dedicados a las actividades de hogar y agricultura familiar
Nº de jub./desemp.	Actividades	Miembros que no cuentan actualmente con un trabajo

Cada una de estas variables corresponderá a una neurona en el algoritmo de clasificación no supervisado SOM, detallado en la sección 2.6. , con el cual se clasifican los 44 hogares que componen la comunidad.

En función de disponibilidad de equipos de medición, se ha considerado un tamaño de 3 filas y 2 columnas de la matriz U de distribución de neuronas en un plano hexagonal. Asumiendo una

distribución gaussiana como función de vecindad, se obtiene los resultados presentados en la Figura 3.17, donde cada hogar es identificado por una abreviatura que referencia al jefe de hogar en el formato *Nombre*_{apellido}.

A partir de los resultados obtenidos, se tiene la clasificación de 5 tipos de hogares y un grupo vacío. A cada grupo se le ha etiquetado con un nombre de clase con el que se le referenciará en el resto del presente trabajo. Los nombres de clase junto con la cantidad de miembros pertenecientes a él se presentan a continuación en la Tabla 3.8.

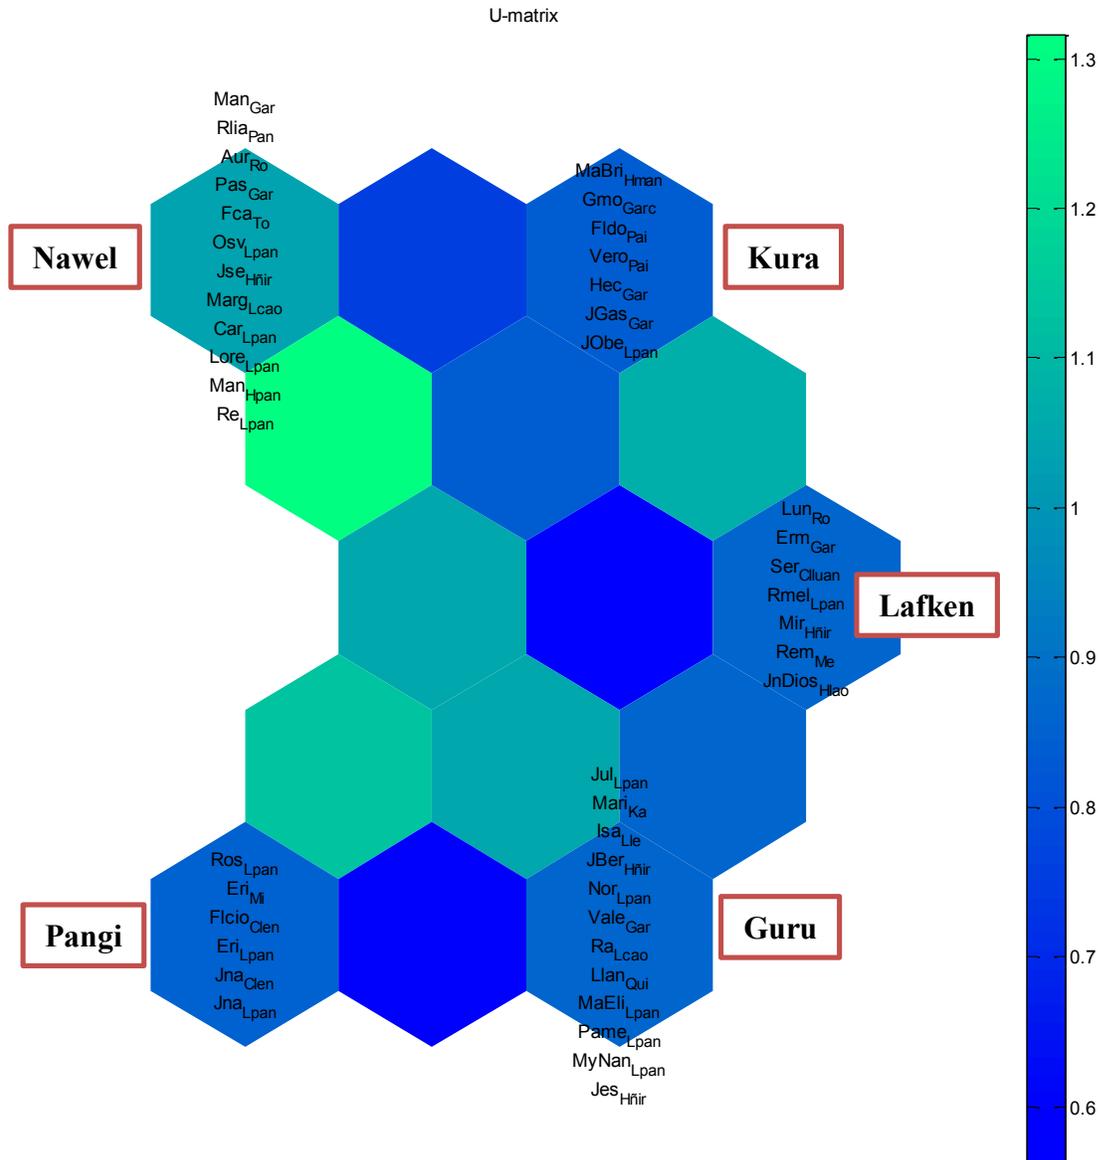


Figura 3.17: Agrupación de hogares obtenidas a través del algoritmo SOM.

Tabla 3.8: Resumen de clasificación de hogares.

Clase	Traducción⁴	Nº de hogares
Nawel	Tigre - Jaguar	12
Kura	Piedra - Roca	7
Lafken	Mar	7
Guru (Gürü)	Zorro	12
Pangi	León - Puma	6
TOTAL		44

Para identificar las características que definen cada clase se ha realizado un análisis compuesto por el estudio de distribución de frecuencias en cada una de las variables, presentado en la sección C.1. del Anexo C; y de sus principales índices estadísticos: media, desviación estándar, mínimo y máximo, presentados en la sección C.2. del Anexo C. De esta forma, una variable con baja dispersión representa una característica definida de su clase correspondiente, obteniendo así las siguientes definiciones de clase:

- **“Nawel”**: Familias conformadas por 4 o menos integrantes, con presencia de 1 o 2 adultos mayores, sin jóvenes y en general sin adultos. No hay estudiantes, a lo más 1 miembro se dedica a la agricultura y 1 o 2 miembros son jubilados/desempleados.
- **“Kura”**: Familias pequeñas conformadas por 2 o 3 integrantes, compuestas por 1 adulto y por lo general sin jóvenes. Un miembro se dedica a la agricultura, no hay estudiantes, ni jubilados/desempleados y en general no hay dueña de casa.
- **“Lafken”**: Familias conformadas por lo general 3 integrantes, compuesta por 2 o 3 adultos, a lo más 2 jóvenes y sin adultos mayores. A lo más 1 miembro se dedica a la agricultura, 1 es dueña de casa, no hay estudiantes, ni jubilados/desempleados.
- **“Guru”**: Familias clásicas de al menos 4 integrantes, compuestas por 2 adultos, por al menos 2 jóvenes y sin adultos mayores. En general hay 2 estudiantes y 1 dueña de casa. A lo más un miembro se dedica a la agricultura. A lo más un miembro se dedica a la agricultura y no hay jubilados/desempleados.
- **“Pangi”**: Familias muy numerosas, de al menos 5 integrantes, por lo general compuesta por 2 jóvenes y al menos 3 adultos. 2 miembros se dedican a la agricultura y a lo más hay 1 jubilado/desempleado.

⁴ Traducción desde el mapudungun, lengua del pueblo Mapuche.

Como característica global, se tiene que las familias en general no cuentan con miembros que posean un trabajo establecido, por lo que esta variable no corresponde a un elemento diferenciador de clases. Por otro lado, las definiciones obtenidas son consecuentes con respecto a las distancias entre clases representadas en la Figura 3.17. A modo de ejemplo, la definición de la clase “Nawel” tiene bastantes similitudes con la de la clase “Kura”, mientras que, por otro lado, es muy distinta la definición de la clase “Guru”.

Posteriormente, ya realizado el proceso de clasificación, se realiza el registro de datos de consumo de un miembro representativo de cada clase. Las características de cada medición se muestran en la Tabla 3.9, donde es necesario mencionar que la dificultad asociada a la condición de aislamiento de la comunidad de estudio, junto con las constantes interrupciones de servicio no programado que provocan pérdidas de información, son las principales razones por la que en algunas clases se dispone de un mayor registro de datos que otros. La Figura 3.18 presenta el perfil diario promedio de cada una de las clases, considerando un tiempo de muestreo de 1 [hr].

Tabla 3.9: Registro de datos por clase.

Clase	Fecha de inicio	Fecha de término	Días de muestreo
Nawel	26-ene-2016	26-mar-2016	24
Kura	04-ago-2015	16-mar-2016	57
Lafken	08-ene-2016	28-abr-2016	23
Guru	06-ene-2016	10-abr-2016	35
Pangi	27-ene-2016	12-mar-2016	36

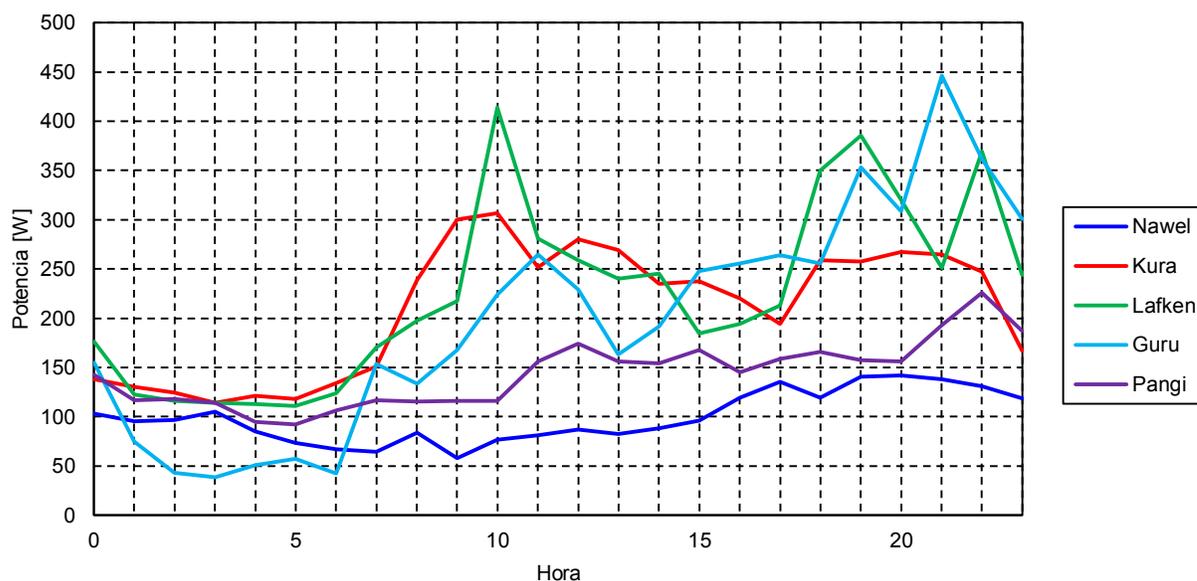


Figura 3.18: Perfiles de carga promedio por clase.

A partir de la Figura 3.18 es posible observar consistencia entre las consideraciones tomadas y los resultados obtenidos. A modo de ejemplo, una familia de la clase “Nawel” está principalmente compuesta por adultos mayores que a la vez son jubilados, por lo que su mayor permanencia en sus hogares es reflejada en un perfil de consumo plano. Por otro lado, una familia de la clase “Lafken”, compuesta por un grupo etario más joven, es más dependiente de los equipos eléctricos y electrónicos, lo que se condice con un consumo promedio más alto; además de poseer un consumo más variable y más similar a un consumo residencial urbano, debido a la actividad productiva de sus miembros que se desarrolla principalmente durante las horas de tarde.

A continuación, se procederá a dar variabilidad a los perfiles de consumo obtenidos mediante cadenas de Markov.

3.6.2. Variabilidad en perfiles de consumo.

En la presente sección se expone la implementación del método descrito en la sección 2.7.2. para los datos disponibles de cada una de las clases que representan un hogar en la comunidad de estudio.

En un análisis previo al diseño del simulador de datos de consumo, se ha determinado que no existe variación del comportamiento y hábitos de las familias entre días de semana (laboral) y días de fines de semana, tal como se puede observar en el ejemplo de la Figura 3.19, donde la potencia promedio medida en la clase “Pangi” es de 141.70 [W] para un día laboral y es de 147.89 [W] para un día de fin de semana. Por lo tanto, en el proceso de generación de perfiles de consumo no se ha diferenciado los datos medidos en función del día registrado.

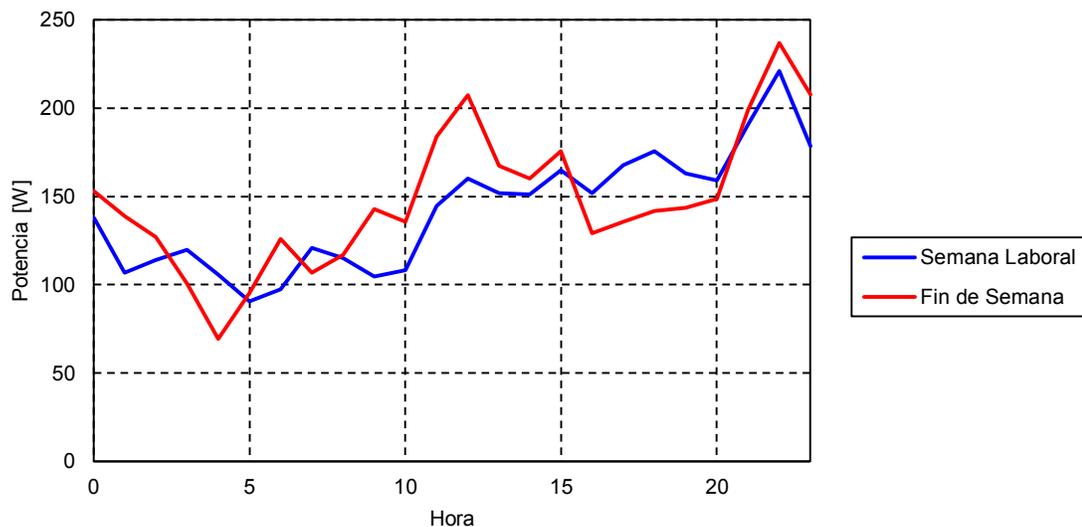


Figura 3.19: Diferenciación del perfil de carga promedio de la clase Pangi para distintos días de la semana.

En un análisis heurístico, se ha determinado de 2 a 3 grupos de datos de demanda eléctrica diaria para cada clase, al que se le asociará una cadena de Markov, correspondiendo aproximadamente a

consumos bajos, medios y altos. En general, el consumo alto se registra en horas de la noche, mientras que un consumo medio y bajo se mide durante la tarde y madrugada respectivamente. En clases donde se ha determinado 2 grupos de datos, dicha tendencia es menos marcada.

Tal como se ha mencionado en el procedimiento, las características a utilizar para describir los niveles de potencia consumida en cada tiempo de muestreo son el valor mínimo, máximo y medio de consumo. Minimizando la expresión (2.87), se obtienen los rangos de cada agrupación por clase, presentado en la Tabla 3.10, donde de acuerdo a la notación utilizada, s corresponde a la cantidad de grupos de datos, l_q , con $q \in \{1, 2, 3\}$ corresponde a la cota temporal inferior de cada grupo.

Ya agrupados los datos, se prosigue con la determinación de la máxima cantidad de estados para cada cadena. Para obtener una cantidad aceptable de estados, que otorguen variabilidad suficiente en los datos de consumo que serán generados, se ha seleccionado como parámetros de diseño un valor de $r = 0.25$ y $p^* = 0.25$ con una iniciación del algoritmo con $m = 8$ estados. La Tabla 3.10 presenta la cantidad de estados obtenidos m_q para cada q grupo de datos por clase.

Tabla 3.10: Características de grupo de datos de consumo por clase.

Clase	Nº de grupos	Cota inferior [hr]			Nº de estados		
	s	l_1	l_2	l_3	m_1	m_2	m_3
Nawel	2	01	17	-	3	1	-
Kura	3	09	17	24	7	3	3
Lafken	3	01	10	19	2	3	2
Guru	3	01	08	22	3	3	4
Pangi	2	01	13	-	8	8	-

Dada la metodología utilizada, se deduce que existen grupos, como por ejemplo el conjunto S_2 de la clase “Nawel” y los conjuntos S_1 y S_3 de la clase “Lafken”, en que existen pocos datos por estado que llevan al algoritmo a determinar 1 o 2 estados como la máxima cantidad de estados para la representación de los datos medidos. Dicho efecto es consecuencia de la escasez de registro de datos, ya que tal como es posible observar en la Tabla 3.9, en las clases mencionadas se disponen de una menor cantidad de días de muestreo.

Determinado el número de estados por grupo de datos y por clase, se obtiene las cadenas de Markov a través del cálculo del estimador de máxima verosimilitud de la expresión (2.84). Finalmente, dichas cadenas se definen mediante sus MTE que contienen las probabilidades de transición \hat{p}_{ij} ; sus probabilidades iniciales de estado \hat{p}_i ; y los centroides μ_i , que representan el valor de potencia de cada estado. Estos parámetros son presentados en detalle en la sección C.3. del Anexo C.

Las cadenas de Markov forman parte de la base de datos de simulador, con las que se generan realizaciones a partir de ellas. De esta forma, s segmentos de datos de consumo, correspondiente a un intervalo dado día, son concadenados para la obtención del perfil completo simulado.

La Figura 3.20 presenta una realización del simulador por clase, el cual es comparado un día de registro de datos de consumo. La Figura 3.21 presenta el promedio diario de 1000 días de simulación comparado con el promedio diario de los datos medidos de cada clase. Los resultados de desempeño del simulador, a través del índice NMAE definido en la expresión (2.98), se presentan en la Tabla 3.11.

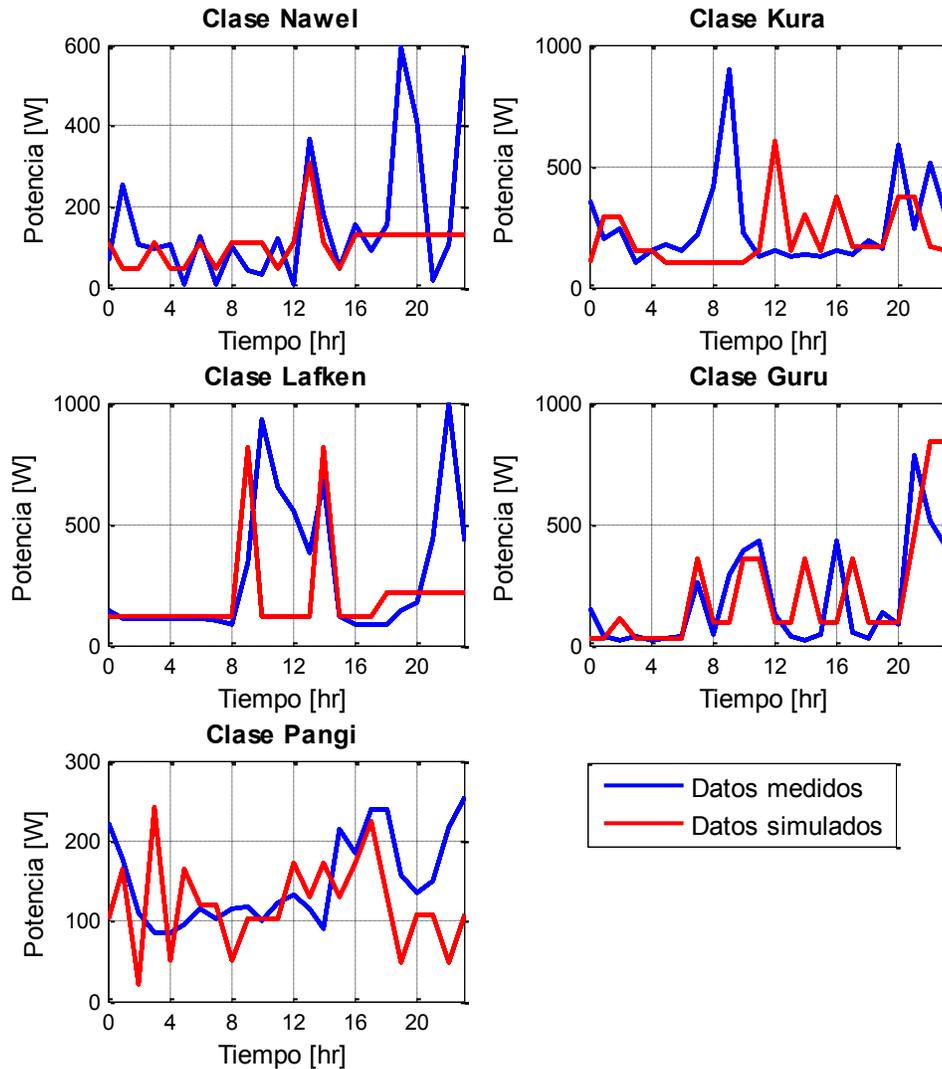


Figura 3.20: Demanda eléctrica por clase en un día tipo.

En la Figura 3.20 es posible observar algunos de los estados definidos por los centroides obtenidos por el procedimiento. Por otro lado, a pesar de que el perfil simulado es distinto al perfil medido (lo cual es un efecto deseado), se tiene que ambos se encuentran en el mismo orden de magnitud de potencia.

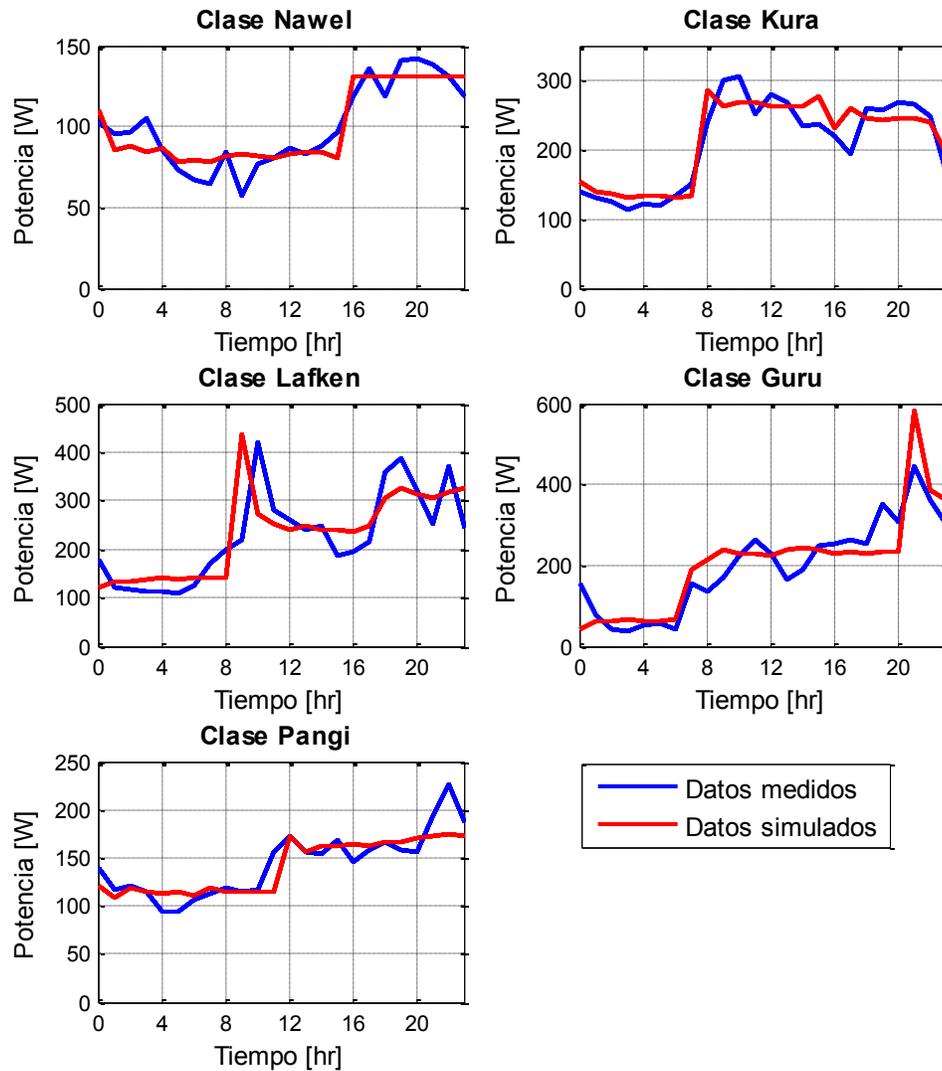


Figura 3.21: Demanda eléctrica promedio por clase.

Tabla 3.11: Medida de error de la demanda eléctrica simulada por clase.

Clase	NMAE [%]
Nawel	9.5425
Kura	10.4037
Lafken	21.4601
Guru	27.3759
Pangli	7.6978

La Figura 3.21 y la Tabla 3.11 reflejan el buen funcionamiento del simulador: los perfiles promedios simuladores tienden a ajustarse al perfil promedio medido; y en 3 clases el NMAE está en torno al 10%, mientras que en las otras 2 es menor al 30%. Las principales fuentes de error son, por un lado, la baja cantidad de estados que provocan transiciones menos “finas”. Por otra parte, el método propuesto no considera a las probabilidades iniciales de estado \hat{p}_i con dependencia del grupo de datos anterior, lo que produce que las mayores diferencias ocurran en la transición de un grupo de datos al otro, tal como se puede observar por ejemplo entre las 9:00 – 10:00 [hrs] en la clase “Lafken”.

A pesar que estos resultados pueden mejorar si se dispone de una mayor cantidad de datos medidos, el error obtenido no debe ser considerado como un mal desempeño del simulador, ya que su principal propósito corresponde es generar datos suficientemente variables que representen distintos escenarios de demanda eléctrica.

Mediante el simulador obtenido, es posible generar un perfil anual de demanda eléctrica de la comunidad representativo, cuyos resultados se presentan a continuación.

3.6.3. Perfil de demanda comunitaria.

Para obtener el perfil de carga anual que supondrá la comunidad al sistema, se ha generado una realización de 365 días del simulador por cada uno de los 44 hogares en función de su clase correspondiente (ver Figura 3.17). El agregado de demanda eléctrica de cada hogar, junto al consumo demanda proveniente de espacios públicos conforman el perfil de carga de la comunidad.

Generalmente, el consumo de espacios públicos difiere del comportamiento típico de un consumo de naturaleza residencial, es decir, no será representado por ninguna de las clases identificadas, por lo que es necesario tratarlo de manera independiente. Por otro lado, en algunos casos, el consumo asociado a dichos espacios corresponde a una proporción no despreciable de la carga total de una comunidad.

La comunidad en estudio dispone con dos espacios destinado a fines público y/o comunitarios: el Centro de Acopio de Algas “Weña Liwen”, que es empleado actualmente como sede comunitaria; y la Escuela Particular Vista Hermosa. Para el presente caso de estudio solo se considerará la demanda eléctrica de este segundo espacio, ya que el Centro de Acopio cuenta con un sistema energético híbrido solar-eólico para su autoabastecimiento.

En la Escuela se dispone solamente de 14 días de registro de su consumo, con un comportamiento menos aleatorio que un consumo residencial y más dependiente del día de la semana medido. En la Figura 3.22 se observa una diferenciación evidente entre el perfil de carga de un día laboral con respecto al perfil de un día de fin de semana, cuya potencia promedio varía de un 89.73 [W] a 15.65 [W]. Dicho comportamiento está directamente relacionado con las actividades de docencia que se practican de lunes a viernes en el establecimiento, donde es posible notar también el receso de almuerzo a las 12:00 [hrs].

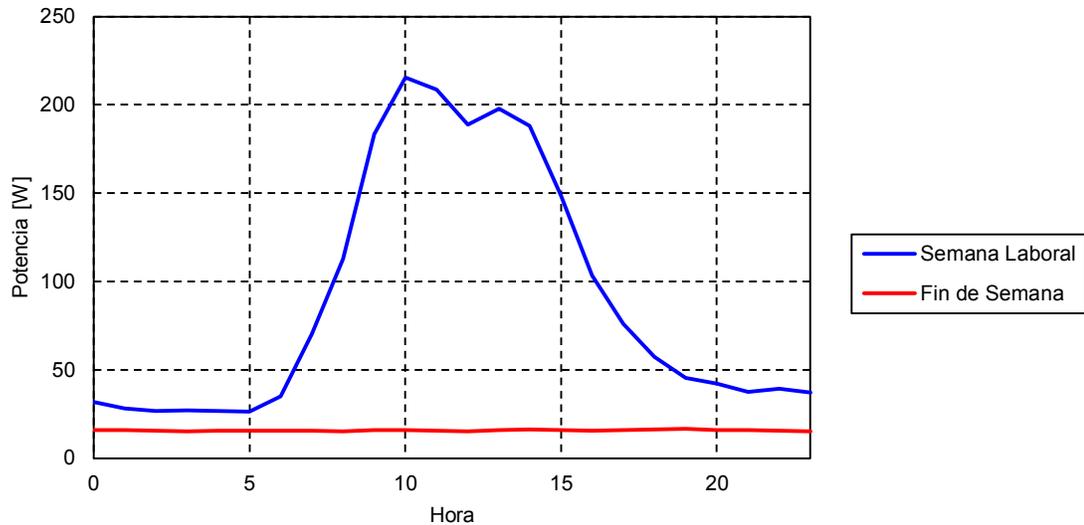


Figura 3.22: Diferenciación del perfil de carga promedio de la Escuela para distintos días de la semana.

De esta forma, debido al comportamiento de consumo predecible de la Escuela, se ha considerado los perfiles de carga promedios de la Figura 3.22 en el agregado de carga, para obtener la demanda eléctrica total de la comunidad.

Luego, para estimar la variación mensual de carga, se ha ponderado el perfil obtenido en función del registro histórico bimestral de consumo energético realizado por la empresa distribuidora Frontel desde el año 2007, presentado en la Figura 3.23. Por un lado, es posible observar que no existe una variación importante en el consumo residencial a lo largo del año, mientras que en la Escuela la principal diferencia de consumo ocurre en los meses estivales (diciembre a febrero).

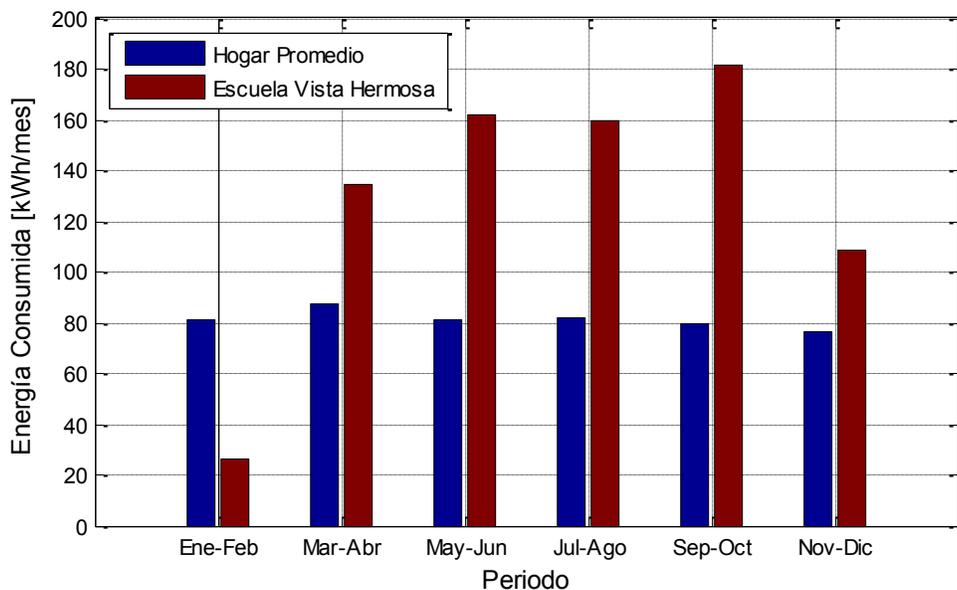


Figura 3.23: Consumo promedio mensual.

Finalmente, con todas las consideraciones ya indicadas, es posible generar un perfil de carga de la comunidad que sea lo suficientemente representativo. En la Figura 3.24 se presenta la realización del simulador para las primeras 96 horas (4 días) del año, donde se observa que cada día presenta un escenario de demanda distinto. Sin embargo, se tiene un patrón en común: un horario de demanda punta alrededor de las 21:00 [hrs] y una baja demanda en horas de madrugada.

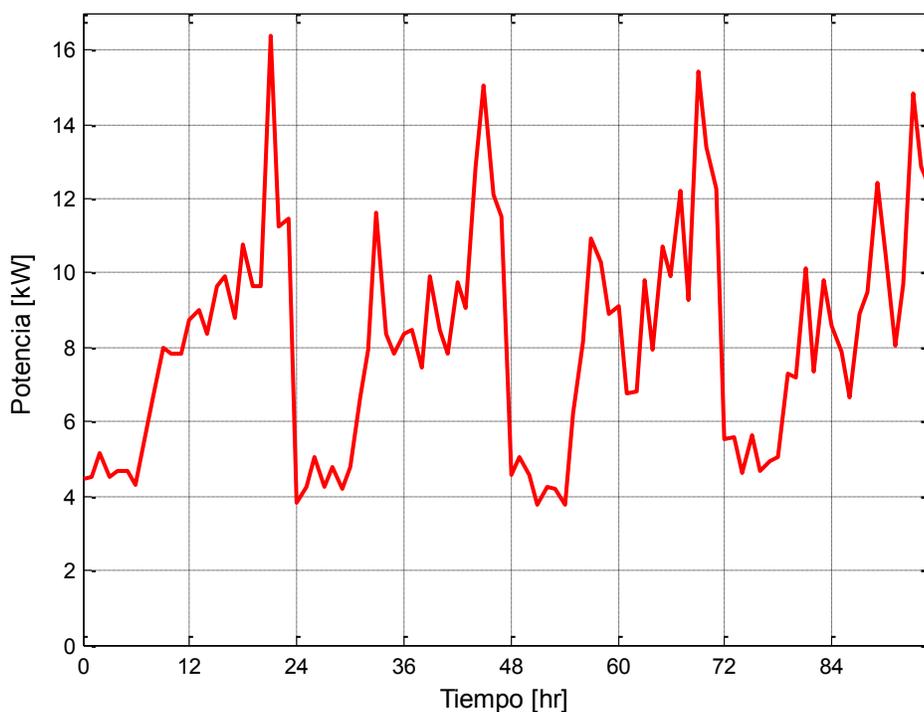


Figura 3.24: Perfil de carga de la comunidad de 4 días de simulación.

Con el fin de validar el simulador de carga propuesto, la Figura 3.25 compara el perfil de carga promedio de la comunidad simulado con las mediciones realizadas por la empresa distribuidora Frontel en agosto y septiembre del año 2016, donde se registró el consumo por subestación en un periodo promedio de 2 días.

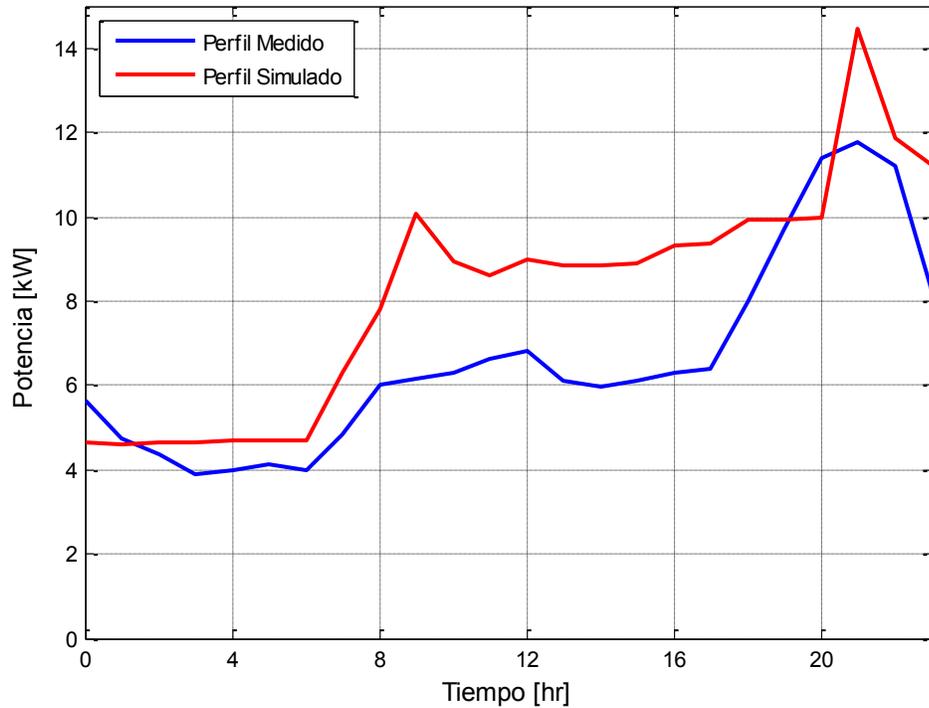


Figura 3.25: Perfil de carga promedio de la comunidad.

La Figura 3.25 refleja el buen desempeño del simulador, cuantificado en un NMAE de 27.5882%, pese a la escasa información de demanda eléctrica con la que se ha dispuesto: medición en solo 5 hogares en un periodo menor a 60 días. Otra fuente de error importante consiste en la diferencia temporal de los distintos registros disponibles, además de que los datos medidos por la empresa distribuidora no son necesariamente representativos del consumo para el resto del año.

De acuerdo a esto, se considera que el simulador propuesto es válido para la aplicación que se busca en el presente trabajo de investigación, cuyos datos generados de demanda eléctrica durante todo un año, se presentan en la Figura 3.26.

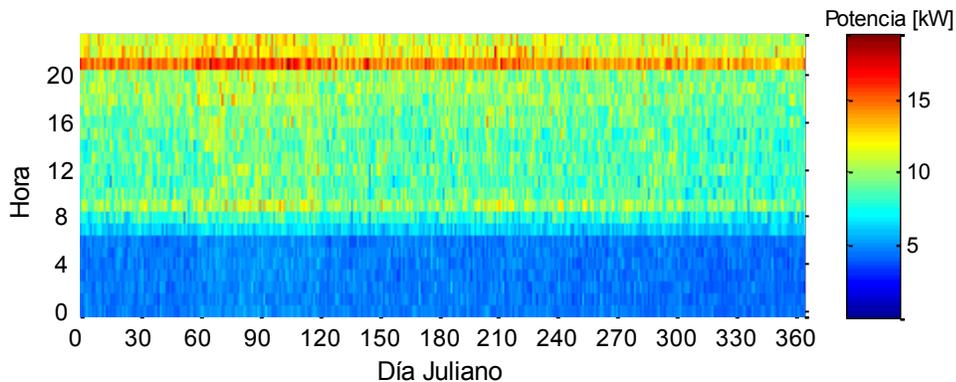


Figura 3.26: Perfil de carga de la comunidad de un año de simulación.

La demanda eléctrica obtenida presenta un factor de carga de 0.42, un consumo promedio de 195.92 [kWh/día], una potencia promedio de 8.16 [kW] y una potencia punta de 19.51 [kW] que se alcanza el 14 de abril (día juliano 105) a las 21:00 [hrs]. Estos datos serán considerados como “datos reales” para la identificación de modelos.

3.6.4. Modelación lineal y modelación difusa de Takagi-Sugeno.

A partir de la serie de tiempo obtenido en el procedimiento anterior, es posible realizar la identificación de modelos de demanda eléctrica. Estos datos correspondientes a un año completo de consumo, con una tasa de muestreo de 1 [hr], es dividido en los siguientes conjuntos:

- **Entrenamiento (60%):** 1 de enero al 6 de agosto;
- **Test (20%):** 7 de agosto al 18 de octubre;
- **Validación (20%):** 19 de octubre al 31 de diciembre.

Considerando una cantidad máxima de 25 auto-regresores, se tiene que el modelo lineal AR identificado es el presentado en la expresión (3.5). En función de los parámetros del modelo obtenido, se tiene que la predicción dada para el instante t es dependiente de la información 18 auto-regresiones, siendo la auto-regresión $y(t - 24)$ la variable más importante, que corresponde exactamente a la información de consumo del día anterior para el mismo instante horario.

$$\begin{aligned} \hat{y}_{lineal}(t) = & 0.1767y(t - 1) + 0.0744y(t - 2) - 0.1191y(t - 3) \\ & + 0.0264y(t - 4) + 0.0389y(t - 5) - 0.0481y(t - 6) \\ & - 0.0186y(t - 7) - 0.0229y(t - 8) - 0.0434y(t - 9) \\ & - 0.0446y(t - 15) - 0.0286y(t - 16) - 0.0197y(t - 17) \\ & - 0.0225y(t - 18) + 0.0296y(t - 19) - 0.0849y(t - 21) \\ & + 0.1024y(t - 22) + 0.0854y(t - 23) + 0.5885y(t - 24) \\ & + 2.7579 \end{aligned} \quad (3.5)$$

De acuerdo al procedimiento de la sección 2.4. cuyos resultados son presentados en la Tabla A.3 de la sección B.1. del Anexo B, el modelo lineal identificado en (3.5) es globalmente estable según Lyapunov.

Empleando los mismos conjuntos de datos, considerando una cantidad máxima de 25 auto-regresores y 6 reglas, se tiene que el modelo difuso de T&S identificado es conformado por 3 reglas, cuyas premisas se muestran en la Figura 3.27 y en la Tabla A.6 de la sección B.2. del Anexo B, mientras parámetros de sus consecuencias son presentadas en la base de reglas de la expresión (3.6). Al igual que en el caso anterior, siguiendo el procedimiento de la sección 2.4. cuyos resultados obtenidos se presentan en la Tabla A.3 de la sección B.1. del Anexo B, el modelo difuso identificado es globalmente estable según Lyapunov.

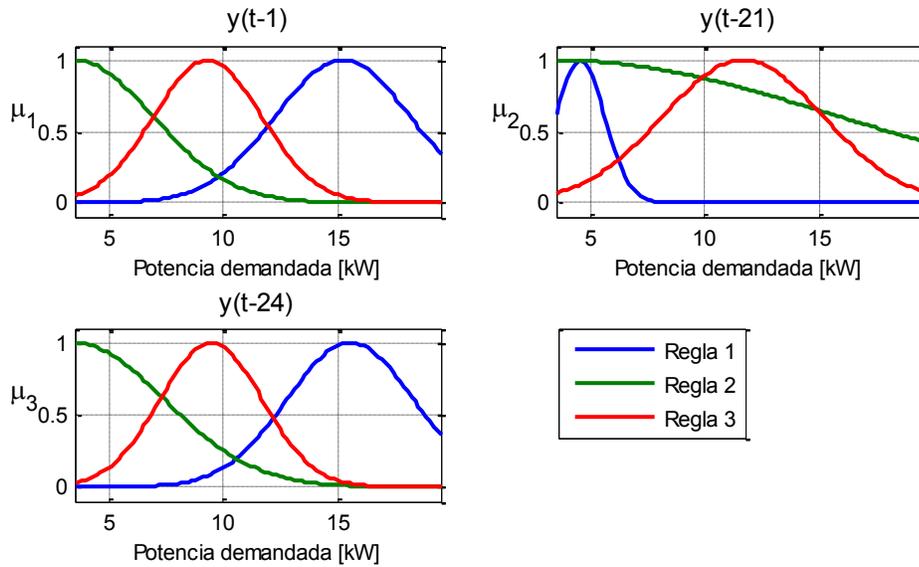


Figura 3.27: Funciones de pertenencia de la demanda eléctrica.

$R^1 : Si$

$y(t-1)$ es MF_1^1 y $y(t-21)$ es MF_2^1 y $y(t-24)$ es MF_3^1

entonces

$$y_1(t) = -0.3725y(t-1) + 0.3790y(t-21) + 0.3124y(t-24) + 12.1494$$

$R^2 : Si$

$y(t-1)$ es MF_1^2 y $y(t-21)$ es MF_2^2 y $y(t-24)$ es MF_3^2

entonces

$$y_2(t) = -0.0605y(t-1) + 0.0365y(t-21) + 0.6582y(t-24) + 1.7216$$

$R^3 : Si$

$y(t-1)$ es MF_1^3 y $y(t-21)$ es MF_2^3 y $y(t-24)$ es MF_3^3

entonces

$$y_3(t) = 0.0711y(t-1) + 0.1040y(t-21) + 0.0519y(t-24) + 7.5233$$

(3.6)

En un análisis global de premisas y consecuencias del modelo, se observa la clara diferenciación entre las reglas que representan tres condiciones de operación:

- **Regla 1 - Demanda punta.**

Si se tiene una alta demanda registrada en el último instante $y(t-1)$ como en el día anterior $y(t-24)$, además de una demanda baja en el instante “intermedio” $y(t-21)$, se tiene las condiciones de demanda en horario punta. El parámetro libre del local es mayor a 12 [kW] y se pondera en igual medida la información obtenida de los tres autorregresores.

- **Regla 2: Demanda baja.**

Las funciones de pertenencia están centradas en 3.5 [kW] con una alta dispersión en el instante “intermedio”, cuya ponderación es la más baja del modelo local. Parámetro libre definido está en torno a 1.7 [kW].

- **Regla 3: Demanda valle.**

Basado en la última información disponible $y(t - 1)$ y en la tendencia del día anterior $y(t - 24)$, se asume una operación actual media en torno a 9.4 [kW]. En un instante “intermedio” $y(t - 21)$ se refleja una demanda mayor, cuya información es la más relevante para la predicción del modelo local. El valor del parámetro libre se estima en 7.2 [kW].

El desempeño en el conjunto de validación a 24 pasos del modelo lineal y modelo difuso de T&S identificados se muestra a continuación en la Figura 3.28 para 120 horas (5 días). La Tabla 3.12 y la Tabla 3.13 presentan el RMSE y MAE de ambos modelos en los tres conjuntos de datos para 1 paso y 24 pasos de predicción.

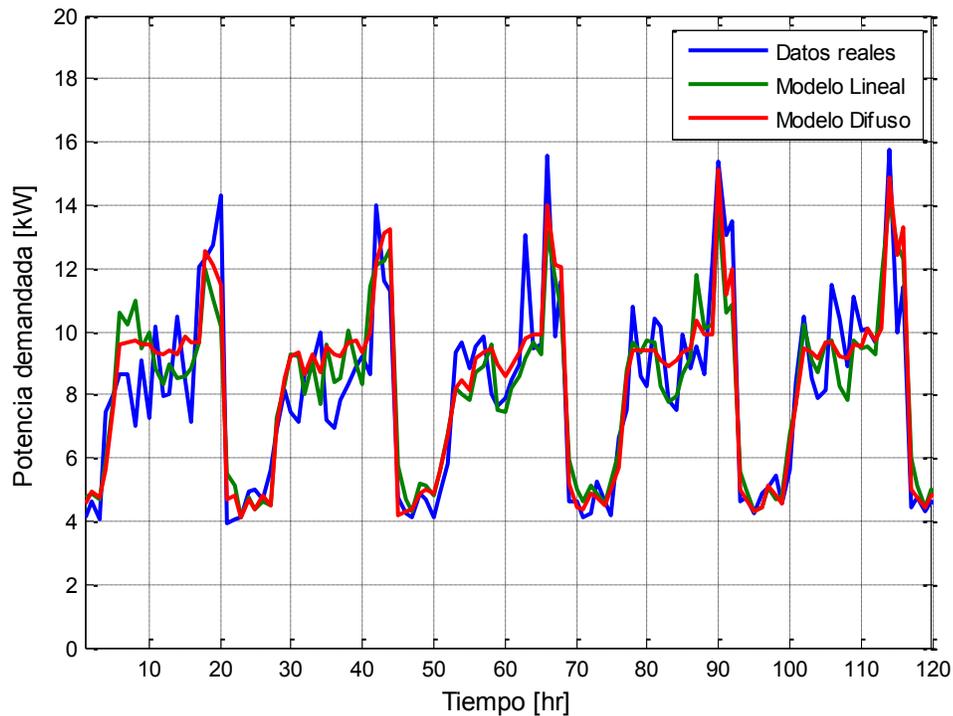


Figura 3.28: Desempeño de los modelos de demanda eléctrica a 24 pasos.

Tabla 3.12: Medidas de error de los modelos de demanda eléctrica a 1 paso.

Conjunto	RMSE lineal [kW]	RMSE difuso [kW]	MAE lineal [kW]	MAE difuso [kW]
Entrenamiento	1.27446	1.16671	0.96881	0.88199
Test	1.23664	1.12797	0.94933	0.86339
Validación	1.20683	1.14041	0.93807	0.86983

Tabla 3.13: Medidas de error de los modelos de demanda eléctrica a 24 pasos.

Conjunto	RMSE lineal [kW]	RMSE difuso [kW]	MAE lineal [kW]	MAE difuso [kW]
Entrenamiento	1.30540	1.18236	0.99340	0.89459
Test	1.25310	1.14879	0.96432	0.87933
Validación	1.22942	1.17685	0.95779	0.90465

De acuerdo a los resultados obtenidos, se concluye que el modelo difuso de T&S identificado posee un mejor desempeño por sobre el modelo lineal. El modelo lineal tiende a seguir el perfil de demanda del día anterior, mientras que el modelo difuso se adapta mejor al perfil actual, tendencia reflejada en la Figura 3.28.

A 1 paso de predicción, el modelo difuso posee un error en torno al 8% menor que el modelo lineal en su evaluación en los conjuntos de entrenamiento y de test, mientras que, en el conjunto de validación dicha mejora es cercana al 5%. Se destaca que dicho desempeño se mantiene a 24 pasos, por lo que ambos modelos se consideran adecuados para aplicaciones que requieran un horizonte de predicción de un día como, por ejemplo, operación del sistema energético.

Finalmente, se opta por escoger el modelo difuso de T&S para generar intervalos de confianza, debido a su mejor desempeño obtenido con una estructura relativamente simple, conformada por tres variables (auto-regresiones).

3.6.5. Inclusión de incertidumbre mediante intervalo de confianza.

La caracterización de la incertidumbre de la demanda eléctrica es determinada mediante el método de la covarianza presentado en la sección 2.5.2. para distintos niveles de confianza que van desde el 10% al 90%. Los resultados obtenidos en el conjunto de datos de validación a 1 paso y a 24 pasos se muestran a continuación en las Figura 3.29 y Figura 3.30, respectivamente para 120 horas (5 días). Su desempeño en el conjunto de validación, representados por los índices CP y NAW, se presentan en la Tabla 3.14.

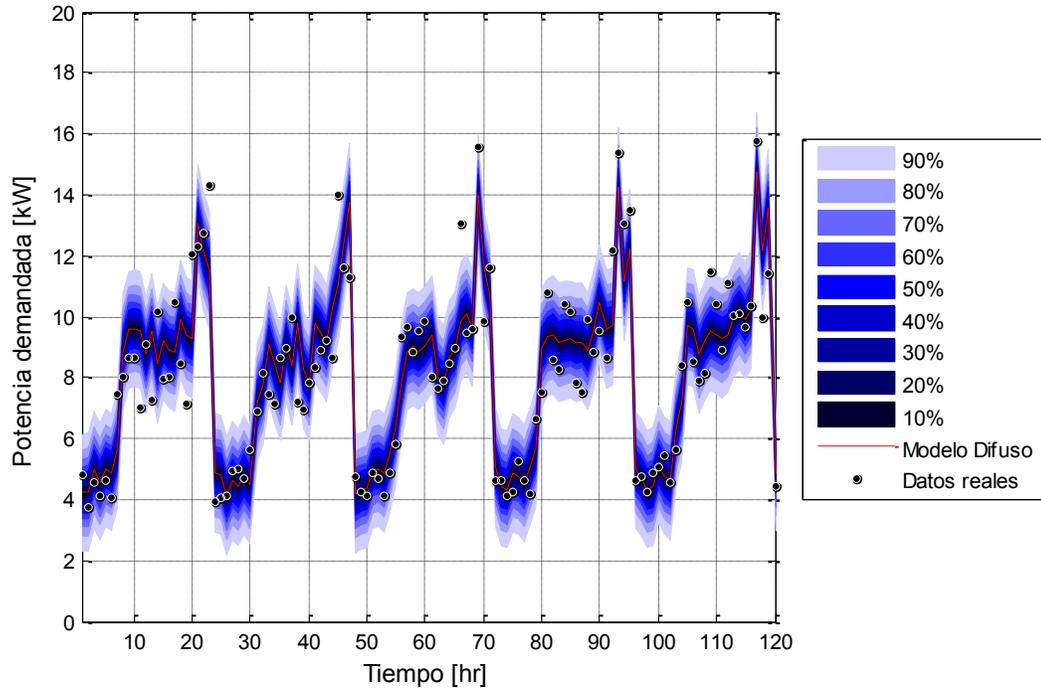


Figura 3.29: Intervalos lineales de la demanda eléctrica a 1 paso.

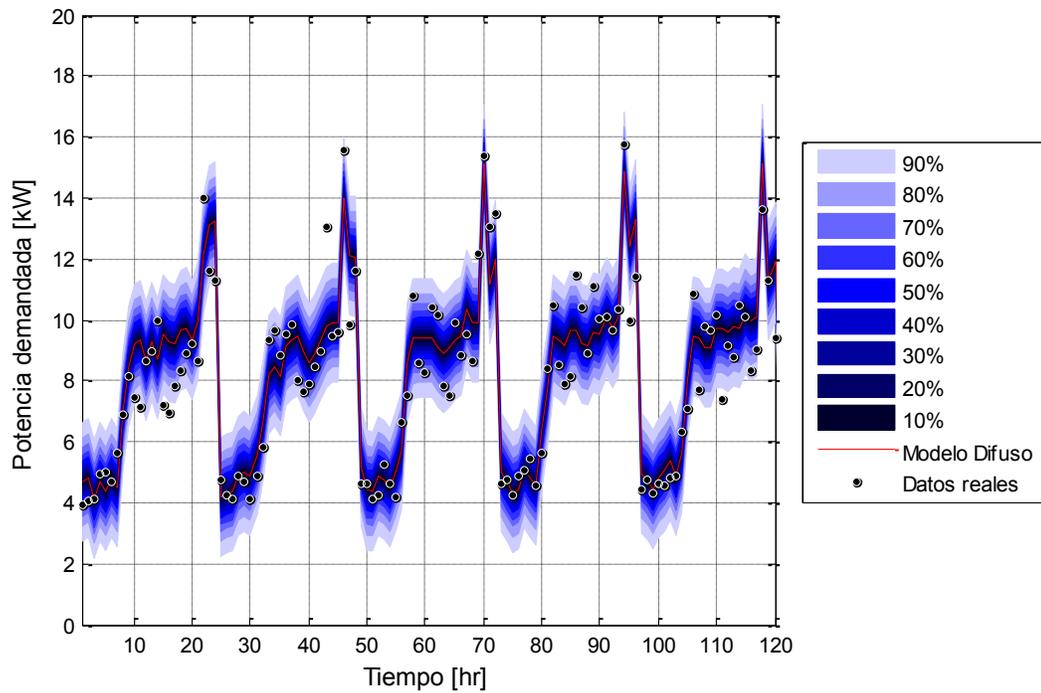


Figura 3.30: Intervalos lineales de la demanda eléctrica a 24 pasos.

Tabla 3.14: Desempeño de los modelos de intervalos lineales de la demanda eléctrica.

Nivel de Confianza	CP 1 paso	NAW 1 paso	CP 24 pasos	NAW 24 pasos
10%	10.48%	1.88%	11.27%	1.99%
20%	20.73%	3.88%	20.19%	3.88%
30%	30.28%	5.92%	29.23%	5.87%
40%	40.65%	8.03%	38.85%	8.03%
50%	50.67%	10.46%	49.59%	10.68%
60%	59.64%	13.45%	59.39%	13.89%
70%	71.34%	17.49%	68.43%	17.55%
80%	79.97%	22.20%	78.58%	22.64%
90%	90.04%	30.06%	89.67%	30.45%

Como se aprecia en las Figura 3.29 y Figura 3.30, los intervalos generados cubren la mayor parte de los datos medidos, con intervalos más suaves en esta última figura. De acuerdo a lo presentado en la Tabla 3.14, los modelos de intervalos se encuentran correctamente identificados, pues su probabilidad de confianza (CP) se encuentra en torno al nivel de confianza sintonizado. A 24 pasos de predicción se mantiene el buen desempeño de los modelos evaluados a 1 paso, pues su CP solo disminuye un 2% mientras que su NAW aumenta un 1% aproximadamente.

Finalmente, a través de estos modelos es posible capturar la incertidumbre asociada a la demanda eléctrica, con intervalos de anchos razonables para las aplicaciones del presente trabajo de investigación.

3.7. Discusión.

En este capítulo se ha presentado y estudiado el caso de estudio, donde se ha determinado que las condiciones de los recursos renovables disponibles eólico y solar son aptas para la instalación de un sistema energético basado en estas fuentes.

Con respecto al procedimiento de clasificación SOM, se destaca también como herramienta para identificar los aspectos socio-demográficos más relevantes que caracterizan a una comunidad u otro sistema de agrupación de individuos. Por otro lado, la metodología de generación del perfil de consumo implementada presenta excelentes resultados, potencialmente aplicables para otros estudios, como por ejemplo en la simulación y emulación de la operación del sistema.

En el proceso de identificación de sistemas, se obtiene que la modelación lineal es suficiente para representar el comportamiento del recurso eólico y el recurso solar, mientras que la modelación

difusa de T&S presenta un mejor desempeño al representar el comportamiento no-lineal de la demanda eléctrica. Con respecto al trabajo en la identificación de modelos de intervalos, se obtiene que el recurso eólico es la variable con mayor nivel de incertidumbre asociada y, por lo tanto, corresponderá a la variable más crítica en el proceso de planificación de la micro-red.

Capítulo 4. Diseño de la micro-red.

4.1. Planificación de micro-redes.

El estudio de planificación de una micro-red es un importante proceso necesario para asegurar la futura operación óptima del sistema energético que cumpla objetivos económicos, técnicos y ambientales [7], [29], [37]. La siguiente sección presenta la metodología y principales modelos empleados para determinar la combinación óptima de los DERs y otros componentes que compondrán la micro-red, de tal forma de garantizar la viabilidad económica del proyecto.

4.1.1. Metodología propuesta.

Como ya se ha mencionado en la sección 2.1.3. , es posible considerar un enfoque de optimización determinista o estocástico en el diseño de la micro-red. En un enfoque determinístico, se considera generalmente la dinámica media de las variables que influyen en el sistema, sin embargo, el rendimiento estará garantizado solo para un escenario, haciendo que el diseño no sea el óptimo en una amplia gama de otros casos. Por otro lado, en un enfoque estocástico, la incertidumbre de la demanda y los recursos energéticos renovables (que son inherentemente estocásticos) se incluyen explícitamente en la optimización, lo que permite garantizar el buen rendimiento bajo un conjunto de escenarios más amplio. El presente trabajo de investigación considera este último enfoque, contemplando la variabilidad en la velocidad del viento, en la radiación solar y en la demanda eléctrica.

La micro-red considerada en este caso de estudio está conectada a la red eléctrica principal. Contempla la evaluación de inclusión de un sistema fotovoltaico y turbinas eólicas como tecnologías de generación mediante los recursos naturales disponibles. También se incluye un banco de baterías y un generador diésel como sistema de respaldo que permitan la operación en isla cuando ocurran fallas fuera de la micro-red. La combinación óptima de componentes se encuentra generalmente minimizando el costo presente neto (CPN) de la expresión (4.2), satisfaciendo siempre la carga eléctrica requerida [7], criterio que es adaptado al final de la presente metodología. El CPN total incluye el capital inicial, el costo de operación y mantenimiento (O&M), y el costo de reemplazo de los componentes que ocurren dentro del ciclo de vida del proyecto.

$$CPN = \sum_g CPN_g \quad (4.1)$$

$$\min_{\{P_{nom,g}, P_g(t), SoC(t)\}} CPN \quad (4.2)$$

Las variables decisión del problema de optimización son $P_{nom,g}$, $P_g(t)$ y $SoC(t)$, donde $P_{nom,g}$ es la capacidad instalada de la unidad de generación g en [kW], $P_g(t)$ es la potencia instantánea de la

unidad de generación g en el instante t en [kW], y $SoC(t)$ es el estado de carga del banco de baterías en el instante t . Bajo esta notación $g \in \{PV, AG, GD, Bat, Red\}$, donde PV representa al sistema fotovoltaico, AG representa a las unidades eólicas, GD al generador diésel, Bat al banco de baterías y Red a la red eléctrica principal.

En el estudio de planificación de micro-redes también se debe incluir una serie de restricciones. La restricción más importante, es el ya mencionado balance de potencia indicado en (4.3), donde la suma de potencia generada por el conjunto de unidades generadoras (y la red) debe ser igual a la demanda de energía de la comunidad para cada instante del periodo de evaluación. Bajo esta notación c representa a cada tipo de consumo, en este caso $c \in \{Com, Prog\}$, donde Com es el consumo de la residencial y de espacios públicos de la comunidad, y $Prog$ es el consumo programado derivado de actividades productivas.

$$\sum_g P_g(t) = \sum_c P_c(t) \quad \forall t \quad (4.3)$$

Las siguientes restricciones están relacionadas con los recursos renovables. La potencia del arreglo fotovoltaico está restringida a las condiciones ambientales, principalmente de la radiación solar disponibles, mientras que la generación eólica es dependiente de las condiciones de velocidad de viento. Dichas relaciones se expresan en (4.4) y (4.5), cuyo detalle se describe en la sección 4.1.2.

$$P_{PV}(t) = f(I(t)) \quad (4.4)$$

$$P_{AG}(t) = f(V(t)) \quad (4.5)$$

Donde $P_{PV}(t)$ y $P_{AG}(t)$ es la potencia fotovoltaica y la potencia eólica en [kW], $I(t)$ es la radiación solar o radiación global horizontal en [kW/m²], y $V(t)$ es la velocidad del viento en [m/s].

Por otro lado, la expresión (4.6) indica que la potencia instantánea de cada unidad generadora para todo t , debe ser igual o menor a su capacidad instalada en la micro-red.

$$0 \leq P_g(t) \leq P_{nom,g} \quad g \in \{PV, AG, GD, Bat, Red\}, \quad \forall t \quad (4.6)$$

En cuanto al banco de baterías, estas no se pueden descargar completamente debido a que afecta su vida útil. En (4.7) se define un estado de carga mínimo y máximo dependiendo de la tecnología utilizada.

$$SoC_{min} \leq SoC(t) \leq SoC_{max} \quad \forall t \quad (4.7)$$

Finalmente, en (4.8) se indica que el costo de la energía (CoE por sus siglas en inglés) del sistema debe ser menor o al menos igual al actual CoE.

$$0 \leq CoE \leq CoE_{actual} \quad (4.8)$$

En función de estos criterios de optimización se obtiene el diseño de la micro-red más rentable (o menos costosa) desde el punto de vista de una inversión privada. Sin embargo, este criterio deja afuera muchas soluciones que tendrían mayor impacto en una comunidad a través de una mayor reducción de los costos operacionales que implicaría su consumo energético, ya que estas mismas son generalmente proyectos con un alto costo en inversión, que eventualmente podría cubrir un fondo público y/o institución donante.

Debido a esto, en el presente trabajo se propone la modificación de la función objetivo (4.2) a un nuevo criterio de selección, que consiste en la minimización del costo de la energía subvencionado (sin considerar inversión) definido en (4.9), sujeto a no superar un presupuesto destinado a inversión. Dicho criterio es formalizado en (4.10).

$$CoE_{sub} = \frac{C_{anual,sub}}{E_{serv}} \quad (4.9)$$

$$\min_{\{P_{nom,g}, P_g(t), SoC(t)\}} CoE_{sub} \quad (4.10)$$

Con:

$$C_{anual,sub} = CRF \cdot (CAN - Inv), \quad CRF = \frac{r(1+r)^N}{(1+r)^N - 1}, \quad r = \frac{r' - i}{1 + i},$$

$$E_{serv} = E_{serv,com} + E_{serv,prog} + E_{ventas}$$

Donde CoE_{sub} es costo de la energía subvencionado en [\$/kWh], $C_{anual,sub}$ es el costo anualizado de la energía en [\$]⁵, E_{serv} es la energía servida por la micro-red en [kWh], CRF es el factor de recuperación de capital, Inv es la inversión (inicial), r es la tasa real de retorno, r' es la tasa nominal de retorno, i es la tasa de inflación esperada, N es el horizonte de evaluación del proyecto, $E_{serv,com}$ es la energía entregada para consumo residencial y de espacios públicos de la comunidad en [kWh], $E_{serv,prog}$ es la energía entregada para cargas programables destinadas a actividades productivas en [kWh], y E_{ventas} es la energía vendida a la red principal en [kWh].

⁵ [\$] corresponde al símbolo monetario utilizado para referirse al peso chileno. (Al 11 de octubre del 2016, 1 [US\$] = 667.3 [\$], de acuerdo a la Bolsa Electrónica de Chile)

Esta metodología propuesta debe cumplir con las mismas restricciones antes planteadas en (4.3), (4.4), (4.5), (4.6) y (4.7), mientras que la expresión (4.8) se redefine en (4.11) como una condición menos restrictiva que la anterior.

$$0 \leq CoE_{sub} \leq CoE_{actual} \quad (4.11)$$

Finalmente, para incluir el enfoque estocástico al planteamiento de diseño de la micro-red, la propuesta metodológica consiste en caracterizar la incertidumbre de la demanda eléctrica de la comunidad $P_{Com}(t)$ y de los recursos energéticos renovables $V(t)$ e $I(t)$ a través de su representación mediante modelos de intervalos obtenido con el procedimiento indicado en la sección 2.5. , con los cuales es posible simular diferentes escenarios para analizar la factibilidad de la implementación de la micro-red. El balance de potencia de la expresión (4.3) varía de acuerdo a los escenarios generados, y el problema de planificación se resuelve para cada uno de ellos.

En el presente caso de estudio, estos escenarios de simulación se basan en modelos de intervalos de confianza de la velocidad del viento y demanda eléctrica ajustados a un nivel de confianza del 90% obtenidos en las secciones 3.4.2. y 3.6.5. respectivamente. Por otro lado, y por simplicidad para el posterior análisis, solo se ha empleado los datos los datos medidos de radiación solar y no sus modelos de intervalos, ya que de acuerdo a los resultados obtenidos en la 3.5.2. el recurso solar presenta una baja incertidumbre y, consecuentemente, los distintos escenarios posibles de radiación no implicarán modificaciones significativas en el dimensionamiento de los componentes de la micro-red.

Se realiza un diseño del sistema en un escenario base, que corresponde al obtenido con los perfiles anuales medidos de la velocidad de viento, radiación solar y demanda eléctrica. Luego, se considera un escenario desfavorable del recurso eólico y de demanda eléctrica, en el cual la velocidad del viento es igual al límite inferior del intervalo y la demanda es igual a su límite superior. Un tercer escenario corresponde al caso más favorable, donde se asume que el recurso eólico está subestimado y que es mejor representado por su intervalo superior, mientras que la demanda eléctrica se estima a través de su intervalo inferior. Finalmente, la metodología culmina en la selección del diseño final de la micro-red. Esta configuración se elige sobre la base de los criterios técnico-económicos y ambientales más adecuados para la ejecución del proyecto.

4.1.2. Software de dimensionamiento de micro-redes: HOMER.

Para la planificación de la micro-red del caso de estudio, se emplea el software de optimización de sistemas distribuidos HOMER. Dicho software permite la evaluación de diferentes configuraciones de sistemas de energía [99]. A través de un proceso de simulación, los algoritmos de optimización de HOMER determinan la mejor configuración para un sistema híbrido basado en el equilibrio de potencia, las opciones tecnológicas, los costos, la especificación de los componentes y de los recursos disponibles [27].

Dentro de este software, los modelos de mayor interés en el presente trabajo corresponden a los relacionados con las tecnologías de generación mediante las fuentes renovables, es decir, el modelo

de las turbinas eólicas, del sistema fotovoltaico y del sistema de almacenamiento mediante baterías, las cuales se describen a continuación.

En el modelo de las turbinas eólicas, HOMER calcula la potencia de salida del aerogenerador en tres pasos: estima la velocidad del viento a la altura del eje de la turbina eólica, luego calcula la potencia que produciría la turbina eólica a dicha velocidad de viento a una densidad de aire estándar y finalmente se ajusta el valor obtenido para la densidad de aire real.

De acuerdo a la ley de potencia, la velocidad del viento a la altura del eje se estima de acuerdo a la expresión (4.12).

$$V_{eje}(t) = V(t) \cdot \left(\frac{z_{eje}}{z}\right)^\alpha \quad (4.12)$$

Donde $V_{eje}(t)$ es la velocidad del viento en el eje de la turbina eólica en [m/s], $V(t)$ es la velocidad del viento a la altura del anemómetro en [m/s], z_{eje} es la altura de la turbina en [m], z es la altura en la que se encuentra el anemómetro en [m], y α es el exponente de la ley de potencia.

Una vez estimada la velocidad del viento $V_{eje}(t)$, esta se refiere a la curva de potencia de la turbina eólica para calcular la potencia que se esperaría que dicha turbina genere para determinada velocidad en condiciones normales de temperatura y presión (STP) $P_{AG,STP}(t)$ en [kW], obteniendo de esta forma la relación (4.13).

$$P_{AG,STP}(t) = f(V_{eje}(t)) \quad (4.13)$$

Si la velocidad del viento no está dentro del rango definido por la curva, no hay producción de energía, bajo el supuesto que un aerogenerador no produce energía por debajo del límite mínimo (inercia de las aspas) o por sobre su límite máximo (límite de seguridad).

Finalmente, para ajustarse a las condiciones de temperatura y presión reales, la ecuación (4.14) relaciona la potencia obtenida con la densidad del aire.

$$P_{AG}(t) = \left(\frac{\rho}{\rho_0}\right) \cdot P_{AG,STP}(t) \quad (4.14)$$

Donde $P_{AG}(t)$ es la potencia de salida del aerogenerador en [kW]; ρ es la densidad real del aire en [kg/m³]; y ρ_0 es la densidad del aire en condiciones estándar de temperatura y presión, equivalente a 1225 [kg/m³].

Con respecto al modelo del sistema fotovoltaico, para calcular su potencia se comienza con la obtención de la radiación solar que incide sobre un plano inclinado. Adoptando el modelo HDKR (modelo de Hay, Davies, Klucher y Reindl) [100], se tiene que la expresión (4.15).

$$\begin{aligned}
 I_{PV}(t) = & (I_d(t) + I_i(t)\tau_I(t))R_z(t) \\
 & + I_i(1 - \tau_I(t))\left(\frac{1 + \cos\beta}{2}\right)\left(1 + f_{nub}(t)\sin^3\left(\frac{\beta}{2}\right)\right) \\
 & + I(t)\rho_g\left(\frac{1 - \cos\beta}{2}\right)
 \end{aligned} \quad (4.15)$$

Con:

$$\tau_I(t) = \frac{I_d(t)}{I_o(t)}, \quad R_z(t) = \frac{\cos(\theta(t))}{\cos(\theta_z(t))}, \quad f_{nub}(t) = \sqrt{\frac{I_d(t)}{I(t)}}, \quad I(t) = I_d(t) + I_i(t)$$

Donde $I_{PV}(t)$ es la radiación solar global incidente en el arreglo fotovoltaico en $[\text{kW}/\text{m}^2]$, $I_d(t)$ es la radiación directa en $[\text{kW}/\text{m}^2]$, $I_i(t)$ es la radiación indirecta o difusa en $[\text{kW}/\text{m}^2]$, $\tau_I(t)$ es el índice de anisotropía, $R_z(t)$ es la relación de radiación sobre una superficie inclinada con respecto a la radiación sobre una superficie horizontal, β es la pendiente de la superficie en $[\circ]$, $f_{nub}(t)$ es el factor de “brillo del horizonte” que está relacionado con el efecto de nubosidad, I_G es la radiación global horizontal en $[\text{kW}/\text{m}^2]$, ρ_g es la reflectancia del suelo o albedo, $I_o(t)$ es la radiación horizontal extraterrestre promedio en $[\text{kW}/\text{m}^2]$ definida en [101] en función de la ubicación geográfica y hora del día, $\theta(t)$ es el ángulo de incidencia en $[\circ]$ y $\theta_z(t)$ es el ángulo zenit en $[\circ]$.

Generalmente, y en particular en el caso de estudio, los datos de radiación solar disponibles corresponden a la radiación global horizontal sobre la superficie de la Tierra $I(t)$, por lo que es necesario descomponer dicha radiación sus componentes directa y difusa. Para ello, se define el índice de claridad $k_T(t)$ en (4.16).

$$k_T(t) = \frac{I(t)}{I_o(t)} \quad (4.16)$$

De esta forma, es posible emplear la correlación de Erbs et al. [102], que define a la fracción difusa como una función de $k_T(t)$ de acuerdo a la expresión (4.17).

$$\frac{I_i(t)}{I(t)} = \begin{cases} 1 - 0.09k_T & k_T \leq 0.22 \\ 0.9511 - 0.1604k_T + 4.388k_T^2 - 16.638k_T^3 + 12.336k_T^4 & 0.22 < k_T \leq 0.80 \\ 0.165 & 0.80 < k_T \end{cases} \quad (4.17)$$

Estimada la radiación incidente I_{PV} , HOMER calcula la potencia de salida del arreglo fotovoltaico $P_{PV}(t)$ mediante la expresión (4.18).

$$P_{PV}(t) = P_{PV,nom} f_{PV} \left(\frac{I_{PV}(t)}{I_{PV,STC}} \right) \left(1 + \alpha_{PV} (T_c(t) - T_{c,STC}) \right) \quad (4.18)$$

Donde $P_{PV,nom}$ es la potencia nominal del arreglo fotovoltaico en [kW]; f_{PV} es el factor de reducción de potencia; $I_{PV}(t)$ es la radiación incidente obtenida en (4.15) en [kW/m²]; $I_{PV,STC}$ es la radiación incidente en condiciones estándar de test, equivalente a 1 [kW/m²]; α_{PV} es el coeficiente de efecto de la temperatura sobre la potencia en [%/°C]; $T_c(t)$ es la temperatura de celda (fotovoltaica) en [°C] definida en [103] en función de la temperatura ambiente y radiación; y $T_{c,STC}$ es la temperatura de celda bajo condiciones estándar de test.

Por último, para el estudio de planificación de la micro-red se ha considerado la evaluación de un banco de baterías de plomo-ácido como sistema de almacenamiento energético, debido a que es una tecnología madura. Su evaluación se realiza mediante el modelo de batería cinética [104], que determina la cantidad de energía que puede ser absorbida o retirada del banco en cada instante de tiempo. El modelo, representado en el diagrama de la Figura 4.1, consiste en un sistema de dos depósitos: el primero que contiene la “energía disponible”, que corresponde a la energía que es posible extraer inmediatamente para la conversión a corriente continua; y un segundo depósito con la “energía confinada”, que está ligada químicamente y, por lo tanto, no es posible de extraer inmediatamente.

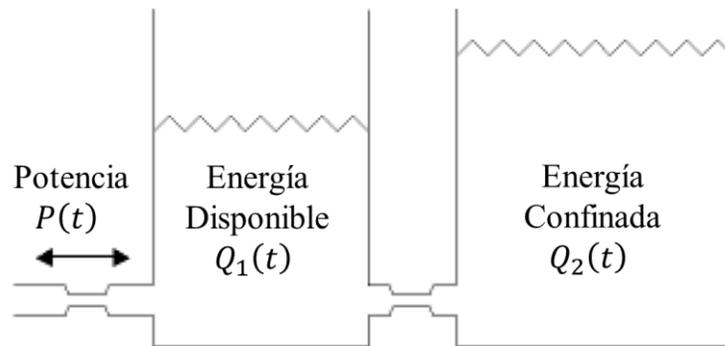


Figura 4.1: Diagrama del modelo de batería cinética.

Las ecuaciones que relacionan la cantidad de energía disponible y confinada en cada instante de tiempo se presentan en (4.19), (4.20) y (4.21).

$$Q_1(t+1) = Q_1(t)e^{-k_{bat}\Delta t} + \frac{(Q(t)k_{bat}c_{bat} - P(t)(1 - e^{-k_{bat}\Delta t}))}{k_{bat}} + \frac{P(t)c_{bat}(k_{bat}\Delta t - 1 + e^{-k_{bat}\Delta t})}{k_{bat}} \quad (4.19)$$

$$Q_2(t+1) = Q_2(t)e^{-k_{bat}\Delta t} + Q(t)(1 - c_{bat})(1 - e^{-k_{bat}\Delta t}) + \frac{P(t)(1 - c_{bat})(k_{bat}\Delta t - 1 + e^{-k_{bat}\Delta t})}{k_{bat}} \quad (4.20)$$

$$Q(t) = Q_1(t) + Q_2(t) \quad (4.21)$$

Donde $Q_1(t)$, $Q_2(t)$ y $Q(t)$ son la energía disponible, energía confinada (no disponible) y el total de energía almacenada para el instante t en [kWh]; k_{bat} es la constante de velocidad de almacenamiento en [1/hr]; Δt es la duración del paso de tiempo, equivalente a 1 [hr]; c_{bat} es la relación de capacidad de almacenamiento; y $P(t)$ es la potencia en [kW] en el instante t que entra al banco de baterías si es positivo, o que sale del banco si es negativo.

4.2. Condiciones y parámetros de diseño.

La presente sección corresponde a las consideraciones de diseño propias de la localidad en estudio y de la tecnología disponible de la cual se tiene información. A continuación, se menciona las características técnicas y económicas generales y asociadas a cada tecnología, para continuar con la estimación de demanda adicional por desarrollo productivo.

4.2.1. Consideraciones generales.

El esquema general de diseño de la micro-red, presentado en la Figura 4.2, consiste en una representación de dos barras de transferencia: una barra DC donde se encuentran conectados el arreglo fotovoltaico y el banco de baterías, realizando la transferencia de energía a través de un convertidor bidireccional (inversor-cargador) hacia y desde una barra AC, donde se encuentran conectados los aerogeneradores, el generador diésel, la red eléctrica principal y las cargas. En esta aproximación no se consideran las pérdidas en las líneas de distribución.

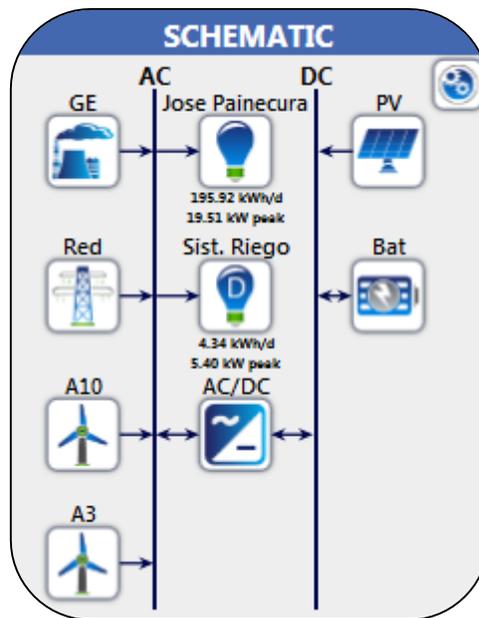


Figura 4.2: Diagrama esquemático de la micro-red.

La planificación y dimensionamiento de las unidades del sistema de micro-red se realiza mediante una evaluación del proyecto, considerando un presupuesto máximo de 320 000 000 [\$] destinado a inversión, una tasa nominal de retorno r' de un 10% en un horizonte de evaluación N de 20 años, de acuerdo a los escenarios de estudio para proyectos de inserción de ERNC al Sistema Interconectado Central (SIC) [105]. Se considera una inflación i de un 3.3%, correspondiente a la mediana del periodo de agosto de los últimos 10 años [106].

Otra variable relevante para la evaluación de las diferentes topologías corresponde a la temperatura ambiente, de la cual depende la densidad de aire ρ para el ajuste de potencia eólica $P_{AG}(t)$ en la expresión (4.14), y la temperatura de celda $T_c(t)$ de la expresión (4.18) para el cálculo de potencia fotovoltaica $P_{PV}(t)$.

Análogamente a las variables de velocidad de viento, radiación y demanda eléctrica, se requiere un set de datos horario de un año completo de temperatura ambiente en [°C], que es obtenida a través de las mediciones realizadas por la estación meteorológica desde el 4 de julio del 2015 al 16 de abril 2016, y completada con la información entregada por el Explorador de Energía Solar. El ciclo anual de la temperatura ambiente se presenta en la Figura 4.3, donde es posible observar su dependencia estacional, encontrándose las temperaturas más altas en los meses de verano, y las temperaturas más bajas y con mayor variabilidad en los meses de invierno.

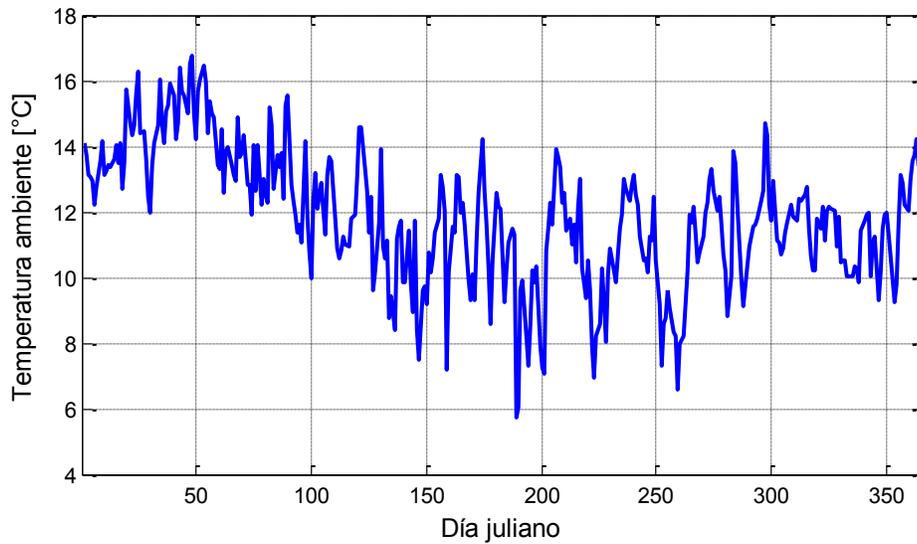


Figura 4.3: Temperatura promedio en Hueñalihuen.

Por otro lado, en función del registro histórico bimestral de consumo energético realizado por la empresa distribuidora Frontel desde el año 2007, se proyecta el aumento de demanda eléctrica residencial y de espacios comunes $P_{Com}(t)$ estimada y modelada en la sección 3.6.

De acuerdo al registro histórico de demanda agregada de toda la comunidad, presentado en la Figura 4.4, el consumo por hogar ha crecido a una tasa promedio de 46.58 [kWh/año]. Tomando el trabajo de mediciones realizado por la misma empresa en agosto y septiembre del año 2016, donde se estima que el consumo promedio de la comunidad es de 297.77 [kWh/día], la tasa de crecimiento de consumo se traduce a un 1.89% anual. Esta tendencia se asumirá constante durante el horizonte de evaluación de proyecto como una primera aproximación en la planificación del sistema energético.

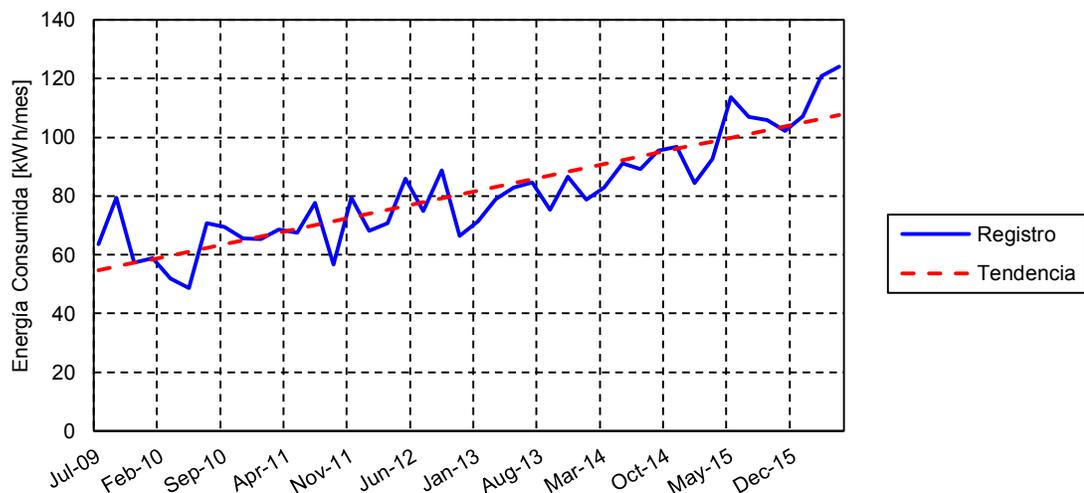


Figura 4.4: Consumo histórico bimestral promedio.

Con respecto a la red de distribución, no se considera costos asociados a su extensión, ya que se hará uso de la red ya existente. No se ha impuesto límite en la capacidad de compra desde la red principal, ya que se asume que la capacidad de las líneas de distribución está muy por sobre la potencia de diseño de la micro-red. En cambio, se impone un límite de 100 [kW] de capacidad de venta, de acuerdo a la Ley de Net Billing [107]. Basado en la publicación de tarifas de suministro eléctrico realizada por la distribuidora local Frontel en el mes de octubre del 2016 [108], se tiene un precio de compra de energía (desde la red) de 176.83 [\$/kWh], correspondiente a la tarifa BT1 (tarifa a clientes residenciales), mientras que el precio de venta (hacia la red) es de 67.49 [\$/kWh]. Sin embargo, debido a la reciente promulgación de la Ley de Equidad Tarifaria, se espera que dentro de los próximos años esta tarifa de compra se reduzca un 26.9% en la comuna de Carahue [109]. De esta forma, para el diseño de la micro-red, se considera el precio actual de compra de energía, realizando posteriormente un análisis de sensibilidad con respecto a la nueva tarifa estimada en 129.26 [\$/kWh].

Se ha cuantificado las interrupciones del servicio eléctrico no programadas de la red principal mediante la información registrada por la distribuidora Frontel en el año 2014, caracterizándose mediante una frecuencia de falla de 43 eventos al año y un tiempo promedio de reparación de 9 [hr] con una variabilidad del 107%. Con dichas características se ha simulado la confiabilidad de la red, mostrado en la Figura 4.5, donde las fallas se representan en color negro.

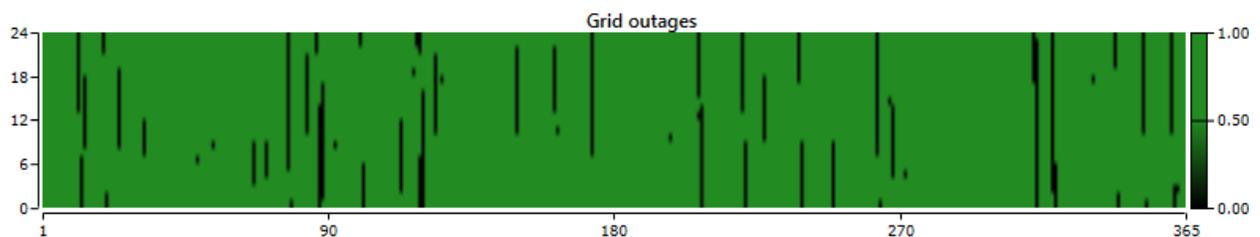


Figura 4.5: Confiabilidad de la red principal.

Estas consideraciones, junto con las características y costos de cada tecnología presentadas en la siguiente sección, son las principales variables definen el dimensionamiento óptimo de la micro-red para el presente caso de estudio.

4.2.2. Características técnicas y económicas de las tecnologías de generación.

Tal como se ha presentado en la Figura 4.2, los principales equipos que componen la micro-red del caso de estudio son las turbinas eólicas o aerogeneradores, el arreglo fotovoltaico, los dispositivos de conversión de potencia, el banco de baterías y el generador diésel, cuyos detalles son descritos a continuación.

- **Aerogeneradores.**

Con respecto a la generación eólica, se considera la velocidad del viento medida y caracterizada en la sección 3.3.1. y los escenarios modelados en la sección 3.4.2. De acuerdo a los datos proporcionados por el Explorador de Energía Eólica, estos datos son tomados a 94 [m.s.n.m] con un exponente de la ley de potencia α de 0.292.

Se evalúan dos tecnologías de aerogeneradores de una vida útil de 20 años correspondiente a unidades del modelo Osiris 10 [110] de 10 [kW] y del modelo Enair 70 [111] de 3.5 [kW], cuyas curvas de potencias son presentadas en la Figura 4.6. Por simplicidad, no se considera pérdidas de potencia en la turbina.

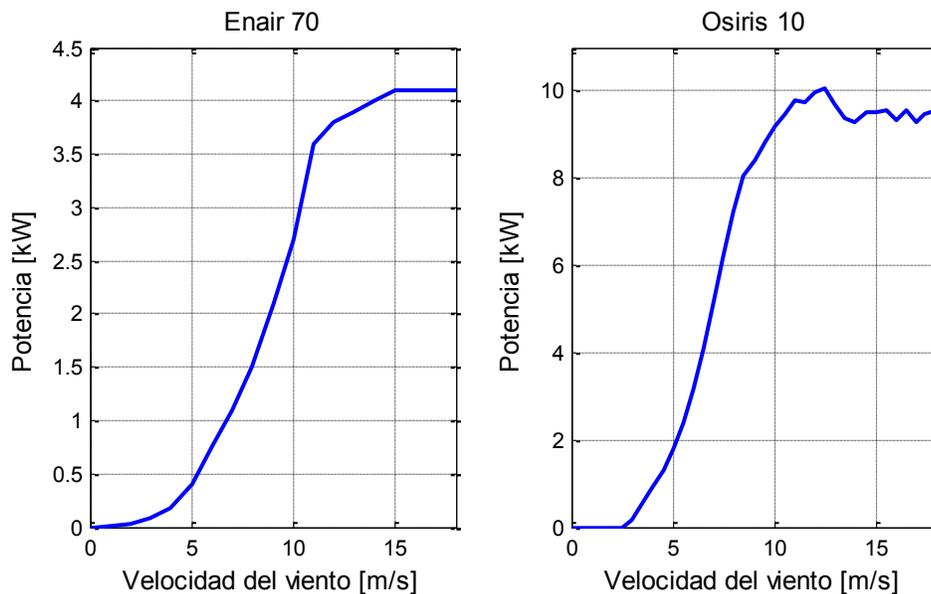


Figura 4.6: Curva de potencia de aerogeneradores de 3.5 [kW] y 10 [kW].

De acuerdo a cotizaciones realizadas a proveedores nacionales, se tienen fuertes economías de escala en los costos de turbinas eólicas, lo que varían en función de la potencia nominal. El costo de inversión de un aerogenerador Osiris 10 es de 93 962 043 [\$], mientras que de un aerogenerador Enair 70 es de 48 909 500 [\$], valores que incluyen el costo de la turbina, del controlador, inversor, y de torre autosoportada de 15 [m]; instalación de faena; obras civiles (fundación); montaje de la torre y canalización eléctrica; cableado, zanja, puesta a tierra y conexión al sistema eléctrico; planos, pruebas y puesta en marcha; instalación de tableros y medidores; recursos humanos; arriendo de maquinaria, herramientas y fletes; costos emergentes y de reserva; utilidades e impuestos. Para el reemplazo de estas unidades, se debe incurrir nuevamente en el total de los costos estimados de inversión.

Se considera costos de O&M equivalentes a 1 409 431 [\$/año] para el aerogenerador Osiris 10, y a 733 642 [\$/año], estimados a partir del 1.5% de la inversión, que se deben invertir al año, de acuerdo a *Danish Wind Industry Association* [112], para la inspección de rodamientos, tornillería, cableado, aspas, amortiguador y engrase cada 6 meses que debe realizar personal calificado.

- **Arreglo fotovoltaico.**

Con respecto a la generación fotovoltaica, se considera la radiación solar medida y caracterizada en la sección 3.3.2. y los escenarios modelados en la sección 3.5.2. De acuerdo a la latitud en que se encuentra la localidad, el sistema se dispone con una inclinación óptima de los paneles β de 38.54° con orientación al norte. Para facilitar la operación y mantención del sistema y, consecuentemente reducir sus costos, el arreglo fotovoltaico no cuenta con un sistema de seguimiento solar horario ni estacional. Se asume una reflectancia del suelo ρ_g de un 20%, correspondiente a un valor típico de áreas cubiertas de vegetación [103].

Se evalúa la tecnología de módulos fotovoltaicos correspondiente al modelo CS6P-250P de *CanadianSolar* [113] de 250 [W]. Estos módulos poseen una vida útil de 25 años, con un factor de reducción de potencia de un 80% para dicho periodo. Su coeficiente de efecto de la temperatura sobre la potencia α_{PV} es de -0.43 [%/°C], la temperatura de celda bajo condiciones de estándar de test $T_{c,STC}$ es de 45 [°C], y el factor de reducción de potencia o eficiencia f_{PV} es de 15.54%.

De acuerdo a cotizaciones realizadas a proveedores nacionales, el costo por cada módulo asciende a 613 842 [\\$]. Al costo total de todos los módulos que componen el arreglo fotovoltaico, se incluye un costo fijo en la inversión de 6 464 556 [\\$] que incluye el gasto en la caja conectora; la instalación de la faena; obras civiles en la estructura de montaje; cableado, zanja, puesta a tierra, instalación eléctrica y conexión al sistema eléctrico; planos, pruebas, puesta en marcha y capacitaciones; recursos humanos, arriendo de maquinaria, herramienta y fletes; fondos de reserva; utilidades e impuestos. Los costos de reemplazo solo contemplan el recambio de paneles, por lo que no se debe incluir nuevamente en los costos fijos de inversión.

Basado en el trabajo de Breyer et al. [114], los costos de O&M son mínimos, estimados en 16 576 [\$/año] por módulo, correspondiente al 1% de su inversión. Este valor incluye limpieza de paneles, verificación de elementos de sujeción y conexión, e inspección del estado de degradación de elementos constructivos.

- **Convertidores de potencia.**

Con respecto al sistema de convertidores de potencia, se considera equipos MultiPlus de *Victron Energy* [115], cuya vida útil de es 20 años. Desde la entrada del inversor poseen una eficiencia del 94% y una tensión de 48 [V_{cc}], mientras que desde la entrada del cargador (rectificador) poseen una eficiencia del 84% y una tensión ajustable a la baja tensión de la red, es decir, 230 [V] y 50 [Hz]. De acuerdo a cotizaciones realizadas en línea [116], se tiene que el costo de un inversor-cargador de 1.6 [kW] es de 1 485 177 [\\$], mientras que para un inversor de 2.4 [kW] es de 1 980 236 [\\$] y de un inversor de 4 [kW] es de 2 640 700 [\\$]. Esta información permite a HOMER cuantificar las economías de escala asociadas al equipo y estimar los costos de un convertidor (o conjunto de convertidores) de una capacidad mayor. El costo de reemplazo corresponderá a incurrir nuevamente el total del costo de inversión.

Los costos de O&M se han estimado a partir del mismo análisis de Breyer et al. [114] para el arreglo fotovoltaico, ya que los convertidores se consideran como parte de este sistema. Estimando dichos costos a partir del 1% de la inversión, se tiene un costo de O&M de 12 376 [\$/año] para el inversor de 1.6 [kW], de 16 502 [\$/año] para el inversor de 2.4 [kW] y de 22 006 [\$/año] para el inversor de 4 [kW].

- **Banco de baterías.**

Con respecto al sistema de acumuladores de energía, se evalúan baterías de plomo-ácido de ciclo profundo de 12 [V] y 100 [Ah] modelo UC100-12 de *Ultracell*, cuya vida útil es de 12 años con un rendimiento de 877 [kWh]. Su operación se simula a través de un modelo genérico propuesto por el software, con un estado de carga mínimo de un 40% de su capacidad nominal, una constante de velocidad de almacenamiento k_{bat} de 0.827 [1/hr] y una relación de capacidad de almacenamiento c_{bat} de 0.403. El peso de cada batería es de 30.4 [kg] y se asumirá que se encuentran inicialmente cargadas. El banco a diseñar estará compuesto por series de 4 baterías, para obtener una tensión de salida de 42 [V] compatible con la tecnología de convertidores evaluados.

A través de cotizaciones en línea se tiene estos equipos tienen un valor de 118 030 [\$] por unidad [117]. Sin embargo, al igual que en el equipamiento anterior, los costos de inversión también incluyen los costos asociados a la instalación y gestión del proyecto, que contempla la mano de obra, el traslado del personal y logística de RRHH necesaria para el montaje, instalación y puesta en marcha del sistema; transporte del equipamiento desde puerto a destino y traslado local; impuestos; y fondos de reserva para costos emergentes, piezas de repuesto, emergencias, inconvenientes y causas de fuerza de mayor. De esta forma, se ha considerado que la instalación implica el trabajo de dos instaladores eléctricos y un arriendo de camioneta, y que el costo de traslado de 1 974 [\$/kg] basado en las cotizaciones del sistema fotovoltaico. Basado en las estimaciones realizadas por Arriaga et al. [118], se valoriza los costos de piezas de repuesto como un 10% del costo de equipamiento e instalación, y un fondo de reserva valorizado en un 15% considerando además el transporte. Finalmente, incluyendo el 19% del total destinado al Impuesto de Valor Agregado (IVA), se estima un costo de inversión de 294 277 [\$] por batería. Es necesario incurrir nuevamente a este costo cada vez que se requiera el reemplazo del banco de baterías.

Para la instalación del banco de baterías es necesaria la construcción de una caseta que permita proteger estos equipos de las condiciones climáticas de la zona, especialmente de la humedad y de la corrosión generada por el ambiente salino. Considerando una estructura de 15.75 [m²], esta se valoriza como un costo fijo, independiente de la dimensión del banco, de 7 350 734 [\$], estimado a partir del proyecto descrito en [119]. Por último, no se consideran costos de O&M, pues las baterías evaluadas son selladas y libres de mantención.

- **Generador diésel.**

Con respecto al sistema de respaldo mediante generación diésel, se considera grupos electrógenos *Kipor* [120], que permiten una partida remota en 5 [min]. Un generador diésel generalmente posee

una vida útil de 15 000 [hr] de operación [121] y como primera aproximación de simulación, se emplea una relación lineal entre el consumo de combustible y su potencia de salida, considerando una proporción de carga mínima de un 25%.

A través de cotizaciones en línea [122], se tiene que el costo de un generador modelo KDE12STA3 de 10 [kW] y 310 [kg] es de 3 025 202 [\$]; mientras que para un generador KDE19STA3 de 20 [kW] y 442 [kg] es de 4 495 790 [\$]; y de un generador KDE60SS3 de 40 [kW] y 1310 [kg] es de 6 641 992 [\$]. Esta información permite a HOMER cuantificar las economías de escala asociadas al equipo y estimar los costos de un generador de una capacidad mayor si es requerido. Al costo del equipamiento, se incluyen los costos asociados a la instalación y gestión del proyecto, siguiendo el mismo procedimiento que en la evaluación del banco de baterías. De esta forma, se estima un costo de inversión de 7 019 652 [\$] para el generador de 10 [kW], de 9 684 562 [\$] para el generador de 20 [kW] y de 15 398 569 [\$] para el generador de 40 [kW]. Estos costos estimados se deben incurrir cada vez que se requiera su reemplazo por fin de su vida útil.

De igual manera que para el banco de baterías, es necesario construir una caseta para el generador (o generadores) del sistema de respaldo. Esta estructura debe ser independiente de la caseta de baterías, debido a que la vibración producida por un generador durante su normal operación, disminuiría la vida útil de las baterías. Considerando una estructura de 20 [m²], esta se valoriza como un costo fijo, independiente de la dimensión del generador, de 8 332 835 [\$], estimado a partir del proyecto descrito en [119].

Los costos de O&M de este sistema de respaldo corresponde al servicio de mantenimiento del generador, que se debe realizar cada 250 [hr] de operación y que contempla gastos en repuestos eléctricos y mecánicos de mantención preventiva (filtros, correas, limpia contactos, cambio de aceite, etc.), mano de obra profesional para el servicio y reparación de componentes [121]. Estos costos se estiman en 273 [\$/hr] (de operación) para el generador de 10 [kW], en 545 [\$/hr] para el generador de 20 [kW] y en 818 [\$/hr] para el generador de 40 [kW].

Basado en la información pública entregada por la Comisión Nacional de Energía (CNE) [123], el precio del diésel se valoriza a 399 [\$/lt], descontando el impuesto específico del 15.4% que se encuentra exento la generación. Sin embargo, en los últimos años se ha observado una marcada baja en el costo del combustible, tendencia que no es posible de asegurar para el horizonte de evaluación del proyecto. La Figura 4.7 muestra el precio mayorista histórico del diésel indicados por ENAP [124], puesto en Concón, que incluyen los costos de logística de transporte y almacenamiento, pero excluye los impuestos que rigen en Chile y el efecto de la aplicación de los fondos de estabilización de precios.

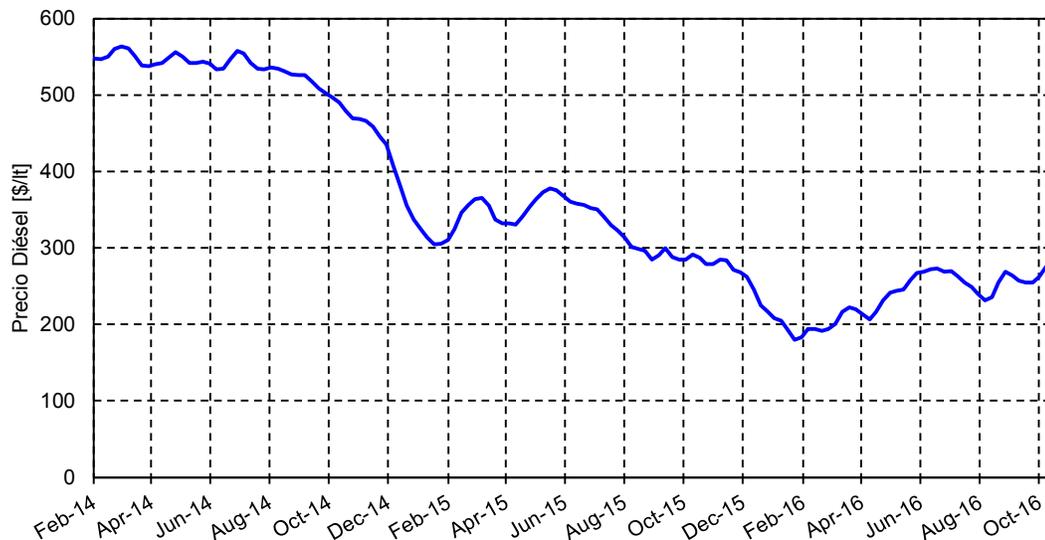


Figura 4.7: Precios mayoristas históricos del diésel.

A través de esta información, se estima que el máximo valor histórico del diésel en la estación de servicio más cercana es de 701 [\$/lt]. De esta forma, para el diseño de la micro-red, se considera el precio actual del diésel, realizando posteriormente un análisis de sensibilidad con respecto a su máximo precio estimado.

Estas tecnologías son las responsables de abastecer la demanda eléctrica total $P_c(t)$, que se compone de la demanda residencial y de espacios comunes $P_{Com}(t)$, estimada y modelada en la sección 3.6. , además de la demanda adicional por desarrollo productivo $P_{Prog}(t)$, descrita en la siguiente sección.

4.2.3. Demanda adicional por desarrollo productivo.

En el estudio de planificación de la micro-red del presente caso, el dimensionamiento de los distintos componentes del sistema se realiza no solo para abastecer la demanda actual $P_{Com}(t)$, sino que también para suministrar de energía a otras cargas adicionales que promuevan el desarrollo productivo de la comunidad y que, ya sea por restricciones técnicas y/o económicas no es posible abastecer bajo las condiciones actuales.

De acuerdo a los resultados obtenidos en las entrevistas y encuestas realizadas a la comunidad en el periodo de mayo a septiembre del 2016, ha sido posible identificar una serie de necesidades existentes relacionadas con el desarrollo de sus actividades productivas, principalmente agrícolas. Dentro de ellas, se destaca la necesidad de un sistema de extracción de agua para riego, debido a que este supondrá una demanda energética adicional no despreciable. Dicho sistema, concebido como un conjunto de motobombas y estanques de almacenamiento de agua, se ha de considerar como una carga eléctrica programable $P_{Prog}(t)$, abastecida principalmente con los excedentes provenientes de la generación solar y eólica.

Una carga programable es una carga eléctrica que debe cumplirse dentro de un periodo de tiempo definido (un día), sin demandar necesariamente un nivel de potencia en un determinado instante de tiempo. Este tipo de cargas poseen algún sistema de almacenamiento asociadas a ella, como es el caso del sistema de riego propuesto, donde existe flexibilidad respecto a cuándo debe funcionar las motobombas, siempre y cuando los estanques de agua de no se sequen.

Según la información recopilada en las encuestas y trabajos participativos con la comunidad, se ha determinado que los tres cultivos más importantes corresponden a la papa, trigo y avena, cuya temporada de producción y superficie requerida se presentan en la Tabla 4.1.

La estimación de superficie que efectivamente requiere de riego en un cultivo de papas se ha obtenido del estudio realizado por Guglielmetti & Covarrubias [125], donde se calcula la distancia óptima sobre hileras de siembra. Considerando que cada planta ocupa una superficie de 40[cm] x 40[cm] y que una distancia adecuada entre hileras es de 70 [cm], se obtiene un factor de ocupación de 0.36, con lo que se obtiene la superficie efectiva que se requiere de riego. Por otro lado, para la producción de trigo y de avena, es posible emplear toda la superficie disponible para su cultivo, por lo que el factor de ocupación es 1.

Tabla 4.1: Requerimientos de cultivo.

Cultivo	1° Temporada	2° Temporada	Superficie	
			Total [Ha]	Efectiva [Ha]
Papa	Julio - Diciembre	Septiembre - Marzo	8.25	2.97
Trigo	Agosto - Enero	-	7.50	7.50
Avena	Agosto - Enero	-	4.35	4.35

La cantidad de agua removida desde el suelo y la planta se denomina evapotranspiración [126], determinada según la expresión (4.22).

$$ET = ET_p \cdot k_c \quad (4.22)$$

Donde ET es la evapotranspiración en [mm/día]; ET_p es la evapotranspiración potencial en [mm/día], que corresponde a la componente de pérdida de agua producida por factores ambientes, tales como radiación, temperatura ambiental, humedad y viento; y k_c corresponde a la constante de cultivo, que determina la transpiración vegetal de un determinado cultivo.

La evapotranspiración potencial ET_p , presentada en la Figura 4.8, es estimada a partir del estudio realizado por el Centro AGRIMED [127] para la localidad de Nehuentue, por ser la ubicación más cercana al presente caso de estudio.

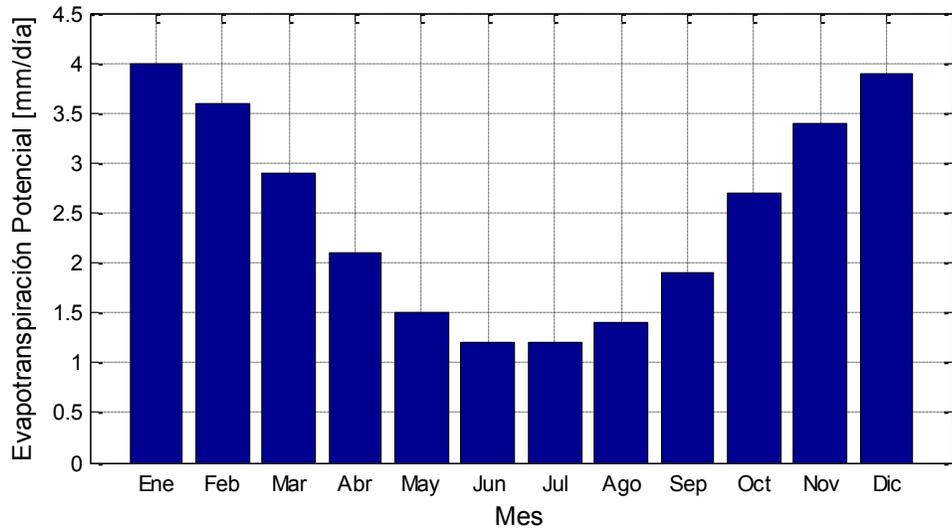


Figura 4.8: Evapotranspiración potencial en la localidad de Nehuentue.

La constante de cultivo k_c depende tanto de la especie vegetal como de su estado de desarrollo. En la Tabla 4.2 se muestran los valores de k_c basados en los estudios de James [128], Millar [129] y de Stewart y Nielsen [130], donde es posible notar que los requerimientos de agua más altos ocurren en las etapas medias de desarrollo de la especie, y que la mayor demanda corresponde al cultivo de papas.

Tabla 4.2: Coeficiente de cultivo de la papa, trigo y avena.

Cultivo	Inicio (0% - 20%)	Desarrollo del Cultivo (20% - 40%)	Media estación (40% - 60%)	Inicio de madurez (60% - 80%)	Madurez fisiológica (80% - 100%)
Papas	0.40 – 0.50	0.70 – 0.80	1.00 – 1.20	0.95 – 1.00	0.65 – 0.75
Trigo	0.30 – 0.40	0.70 – 0.80	1.00 – 1.15	0.60 – 0.70	0.20 – 0.25
Avena	0.30 – 0.40	0.70 – 0.80	1.00 – 1.15	0.60 – 0.70	0.20 – 0.25

Para estimar el requerimiento de riego, es necesario determinar también la humedad aprovechable, que depende del tipo de suelo disponible en la localidad, definida en la expresión (4.23).

$$H_a = (w_{cc} - w_{pmp}) \cdot D_a \cdot z_s \cdot (1 - P_s) \cdot \rho_{H_2O}^{-1} \quad (4.23)$$

Donde H_a es la humedad aprovechable en [mm]; w_{cc} es la humedad retenida o capacidad de campo en [gr/gr]; w_{pmp} es el punto de marchitez permanente en [gr/gr]; D_a es la densidad aparente en [gr/cm³]; z_s es la profundidad del suelo en [cm]; P_s es la pedregosidad, que por simplicidad se asume igual a 0; y ρ_{H_2O} es la densidad del agua, equivalente a 1 [gr/cm³].

Basado en el trabajo elaborado por el CTSyC (Centro Tecnológico de Suelos y Cultivo de la Universidad de Talca) presentado en la sección D.1. del Anexo D, se ha determinado que la serie de suelo corresponde a la asociación Nahuelbuta [131]. De acuerdo al estudio realizado por CIREN (Centro de Información de Recursos Naturales) [132], dicha serie de suelo presenta las características mostradas en la Tabla 4.3, con las cuales es posible determinar que la humedad aprovechable total H_{aT} es de 117.08 [mm].

Tabla 4.3: Propiedades del suelo de la asociación Nahuelbuta.

Propiedad	Notación	Unidad	Pedón 1	Pedón 2	Pedón 3
Límite superior		[cm]	0	27	62
Límite inferior		[cm]	27	62	150
Profundidad del suelo	z_s	[cm]	27	35	88
Humedad retenida	w_{cc}	[gr/gr]	0.320	0.348	0.377
Punto de marchitez permanente	w_{pmp}	[gr/gr]	0.227	0.276	0.317
Densidad aparente	D_a	[gr/cm ³]	1.41	1.02	1.06
Humedad aprovechable	H_a	[mm]	35.41	25.70	55.97
Humedad aprovechable total	H_{aT}	[mm]			117.08

Por último, es necesario estimar el requerimiento de agua ya cubierto naturalmente por lluvias. Para ello, se ha empleado las precipitaciones registradas y publicadas por el Explorador Climático⁶ desde el año 1979 en la estación de Puerto Saavedra, con un 80% de probabilidad de excedencia. Así se asegura que el sistema de riego propuesto se encuentre correctamente dimensionado incluso para años más secos. Los datos de precipitación empleados se presentan en la Figura 4.9, donde es comparado además con la precipitación promedio.

⁶ Herramienta en línea desarrollada por el Centro de Ciencia del Clima y Resiliencia (CR)² e implementada por Meteodata. El explorador permite visualizar una extensa base de datos correspondiente a series de tiempo espacialmente distribuidas y registradas a través de instrumentos in situ o remotos. <<http://explorador.cr2.cl/>>

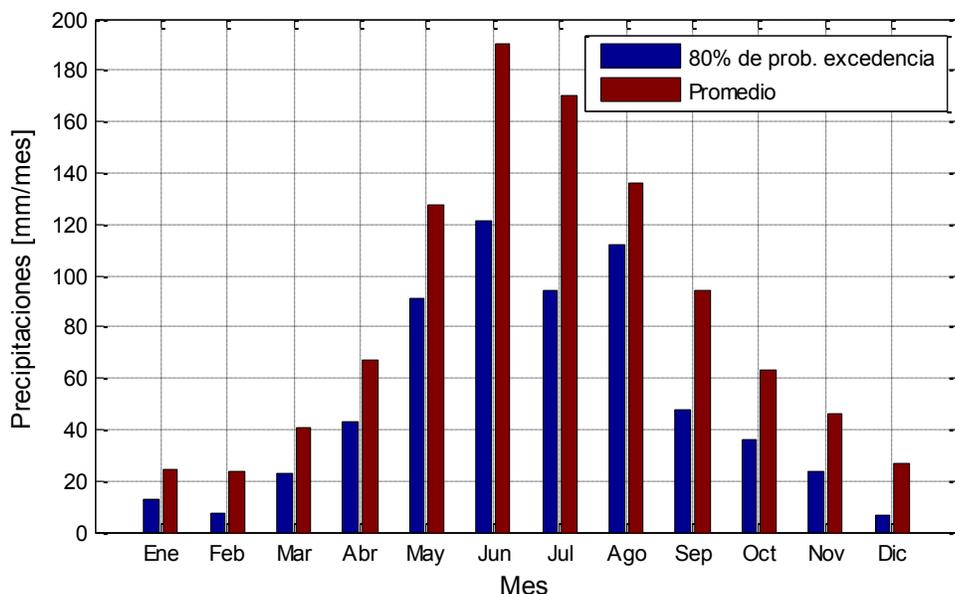


Figura 4.9: Precipitación en la estación de Puerto Saavedra.

De esta forma, se dispone de la información necesaria para dimensionar el sistema de riego y estimar su demanda energética, realizando un balance hídrico mes a mes para cada cultivo a través del siguiente procedimiento.

- Se considera el excedente de agua (retenida por el suelo) del mes anterior como reserva disponible en el mes presente. El algoritmo se inicia en temporada seca, donde la reserva es de 0 [mm].
- Calcular la humedad disponible como la suma de la reserva de agua y las precipitaciones del mes.
- Se define la evapotranspiración real ET_r como el mínimo entre la evapotranspiración ET calculada en (4.22) y la humedad disponible. La diferencia entre la evapotranspiración real ET_r y la humedad disponible corresponderá a la reserva de agua del mes presente, valor que no podrá ser mayor a la humedad aprovechable total H_{aT} obtenida en la Tabla 4.3., pues el resto corresponderá a excedentes no aprovechables de agua.
- Si el excedente calculado es de 0 [mm], entonces hay un déficit que se calcula como la diferencia entre ET y ET_r , que debe ser cubierto por el sistema de riego.
- Se calcula el riego requerido para toda la superficie estimada en la Tabla 4.1, asumiendo una determinada eficiencia.

Finalmente, con la demanda de agua agregada de los cultivos de papa, avena y trigo, es posible determinar la demanda energética que supondrá el sistema. Considerando un sistema de riego comunitario compuesto por 6 motobombas Ebara CD(X)M 200/12 [133], con una potencia nominal de 900 [W] y una capacidad de bombeo de 12 600 [lt/hr], junto con una eficiencia de riego estándar de 0.9, se tiene los resultados presentados la Tabla 4.4 y en la Figura 4.10. Los resultados obtenidos del procedimiento antes descrito para cada cultivo se presentan en mayor detalle en la sección D.2. del Anexo D.

Tabla 4.4: Resultados del sistema de riego para desarrollo productivo.

Mes	Riego total [lt/día]	Llenado de estanques [hr/día]	Demanda energética [kWh/día]
Enero	141 882.41	1.88	10.13
Febrero	55 440.00	0.73	3.96
Marzo	20 845.00	0.28	1.49
Abril	-	-	-
Mayo	-	-	-
Junio	-	-	-
Julio	-	-	-
Agosto	-	-	-
Septiembre	-	-	-
Octubre	-	-	-
Noviembre	120 231.70	1.59	8.59
Diciembre	389 913.89	5.16	27.85

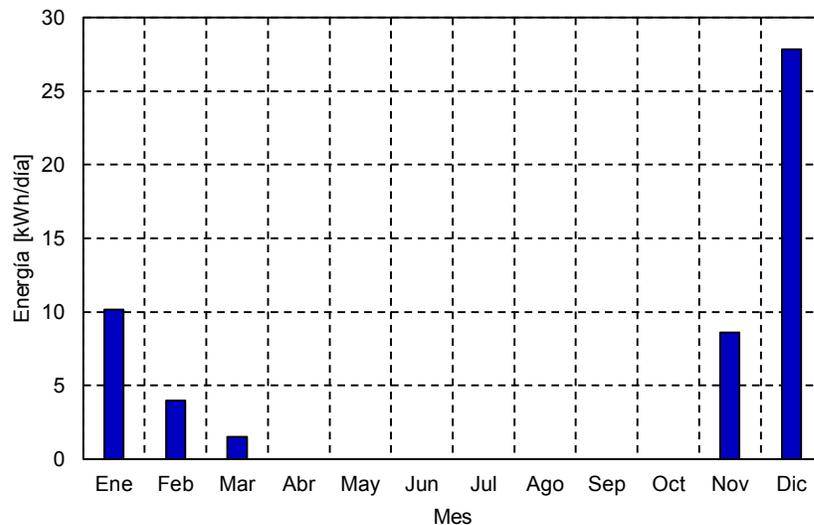


Figura 4.10: Demanda energética por desarrollo productivo.

De acuerdo a los resultados obtenidos, se tiene que la mayor demanda energética se genera en el mes de diciembre, correspondiente al mes más seco del año y donde además se produce la simultaneidad de la temporada de los tres cultivos. Por otro lado, durante los meses de otoño e

invierno, las precipitaciones son suficiente para abastecer la demanda de agua de los cultivos durante dicho periodo.

Las 6 motobombas con las especificaciones antes indicadas implican una potencia peak del sistema de 5.4 [kW]. Estas son suficientes para llenar los estanques en un periodo prudente, cercano a las 5 [hrs] para el mes más crítico. Se ha dimensionado la capacidad de almacenamiento del sistema de correspondiente 120% de la demanda de riego para dicho mes, correspondiente a 467 896.67 [lt] que pueden ser almacenados en 10 estanques de 50 000 [lt], que tardarán en llenarse 6.19 [hr], consumiendo un total de 33.42 [kWh].

Es necesario mencionar consumo energético del sistema de riego se efectúa cuando existen excedentes de generación por parte sistema eólico y/o fotovoltaico, sin embargo, si dichos excedentes no son suficientes para abastecer la demanda energética diaria requerida, el resto de energía se compra desde la red principal.

4.3. Resultados.

A través de la metodología y de los modelos de cada tecnología presentado en la sección 4.1. junto con las características y los parámetros de diseño presentados en la sección 4.2. se obtienen diferentes topologías de micro-redes técnicamente factibles en función de los distintos escenarios simulados. A continuación, se presentan los resultados de diseño, costos y operación.

4.3.1. Resultados de optimización.

Previo al proceso de optimización mediante el software HOMER, se ha considerado indispensable contar con un dimensionamiento banco de baterías adecuado que permita hacer la transición suave del modo conectado a la red a modo isla, en caso que las fallas fuera de los límites de la micro-red. El requerimiento principal para el diseño del banco consiste en ser capaz de abastecer una potencia promedio de 8.16 [kW], en función de la demanda obtenida en la sección 3.6.3. , con una autonomía de 3 [hr], tiempo que se estima suficiente para una partida manual del generador diésel como sistema de respaldo. De esta forma, empleando baterías con las características descritas en la sección 4.2.2. , se requiere 36 unidades para conformar el banco, en una disposición de 4 series compuestas de 9 baterías.

Luego, aplicando el criterio de selección descrito en la sección 4.1.1. , los resultados de diseño obtenidos son presentados en la Tabla 4.5, mientras que los principales costos y resultados de operación son presentados en las Tabla 4.6 y Tabla 4.7, respectivamente para cada uno de los siguientes escenarios:

- **Caso base:** basado en mediciones de velocidad del viento, radiación solar y demanda eléctrica.

- **Caso desfavorable:** basado en el límite inferior del intervalo de velocidad del viento, mediciones de la radiación solar y en el límite superior del intervalo de demanda eléctrica.
- **Caso favorable:** basado en el límite superior del intervalo de velocidad del viento, mediciones de la radiación solar y en el límite inferior del intervalo de demanda eléctrica.

Tabla 4.5: Diseño de micro-redes bajo distintos escenarios.

Configuración	Unidad	Caso base	Caso desfavorable	Caso favorable
Aerogenerador de 10 [kW]	[unid]	0	0	2
Aerogenerador de 3.5 [kW]	[unid]	0	0	0
Arreglo fotovoltaico	[kW]	90	90	30
Banco de baterías	[unid]	36	36	36
Convertor	[kW]	80	80	30
Generador diésel	[kW]	20	20	20

Tabla 4.6: Costos asociados a micro-redes bajo distintos escenarios.

Costos	Unidad	Caso base	Caso desfavorable	Caso favorable
Costo Presente Neto	[MM\$]	394.92	424.87	352.35
Inversión inicial	[MM\$]	297.42	297.42	317.39
Costos anualizados⁷	[MM\$/año]	10.24	12.94	3.86
Costo de la Energía⁸	[\$/kWh]	58.11	69.61	26.33

⁷ Costos anualizados sin considerar inversión ni retorno.

⁸ Costo de la energía subvencionado obtenido de la expresión (4.9).

Tabla 4.7: Resultados de operación de micro-redes bajo distintos escenarios.

Operación	Unidad	Caso base	Caso desfavorable	Caso favorable
Fracción renovable	[%]	69.33	63.84	89.32
Horas de operación del generador diésel	[hr/año]	245.55	260.65	78.90
Consumo de combustible	[lt/año]	786.12	964.62	257.12
Producción del generador diésel	[kWh/año]	2 285.91	2 903.28	751.08
Producción del aerogenerador de 10 [kW]	[kWh/año]	-	-	73 707.66
Producción del arreglo fotovoltaico	[kWh/año]	116 408.00	116 408.00	38 802.68
Compras desde la red	[kWh/año]	44 510.70	57 334.32	12 168.93
Ventas hacia la red	[kWh/año]	64 633.65	57 548.66	52 604.36

Al contrastar los resultados obtenidos en el caso base con respecto al caso actual, es decir, al escenario sin proyecto de micro-red, se tiene que el CPN es un 154.22% mayor a los 156.13 [MM\$] del caso actual, debido a los altos costos de inversión que supone la implementación del proyecto, sin embargo, los costos operacionales del escenario (base) con proyecto son menores a los 14.15 [MM\$/año] del escenario actual, en donde las compras a la red principal ascienden a 83 116.16 [kWh/año] para abastecer el total de la demanda. Valorizando las ventas hacia la red en 4.20 [MM\$/año] en el caso base, se tiene una reducción de un 65.88% en el CoE con respecto al caso actual, generando beneficios directos en la comunidad. Este análisis no se realiza con respecto a los otros dos escenarios presentados, debido a que las condiciones de carga eléctrica no son comparables.

Con respecto a los resultados obtenidos en los distintos escenarios, se tiene que las principales diferencias de diseño consisten en el dimensionamiento de los sistemas de generación fotovoltaico y eólico. Debido a la alta inversión en la instalación de aerogeneradores, si las condiciones reales del recurso eólico son similares o más desfavorables que las estimadas, se propone destinar el presupuesto destinado en una mayor capacidad del arreglo fotovoltaico. Por otro lado, si el recurso eólico es caracterizado de mejor manera por las condiciones representadas en el “caso favorable”, se plantea una configuración híbrida solar-eólica, con la cual es posible depender en menor medida del abastecimiento desde la red principal, obteniendo mayor fracción de generación mediante las fuentes renovables, principalmente eólica y consecuentemente un bajo CoE.

Tomando un criterio conservador, de manera de minimizar el riesgo de capital en la inversión inicial del sistema, se opta por el diseño obtenido para el escenario más desfavorable, que en el presente

caso de estudio coincide con el obtenido en escenario base. Las diferencias obtenidas entre ambos escenarios radican en que en el “caso desfavorable” se considera un mayor perfil de carga. Como consecuencia, en dicho escenario se demanda un 28.81% más de energía desde la red, valorizado en un incremento de 2.63 [MMS\$/año] en los costos operacionales, mientras que las ventas disminuyen un 10.96%. Del mismo modo, en caso de cortes no programados en la red de distribución principal, el generador diésel deberá tomar una carga mayor a la estimada en el “caso base”, lo que implica una mayor demanda de combustible y un aumento del 27.01% en la producción energética mediante este recurso.

Por lo tanto, con esta configuración compone matriz energética principalmente fotovoltaica con un aporte energético anual del 65.84% de la generación total, mientras que el aporte de la generación diésel corresponde al 1.65%. El 32.51% restante es comprando desde la red, permitiendo el abastecimiento continuo de la demanda eléctrica y ventas de excedentes hacia la red, estimada en un 34.51% de la producción total. Es importante mencionar que los resultados están referidos a un año promedio dentro el horizonte de 20 años de evaluación, en donde los primeros años el aporte energético porcentual de los recursos renovables es mayor a los valores indicados, pero a medida que la demanda eléctrica aumenta, se requiere un mayor aporte de la red y del generador diésel.

El aporte energético mensual promedio de cada fuente de generación es presentado en la Figura 4.11, mientras que en la Figura 4.12 presenta, de forma resumida, el desglose del CPN de la micro-red.

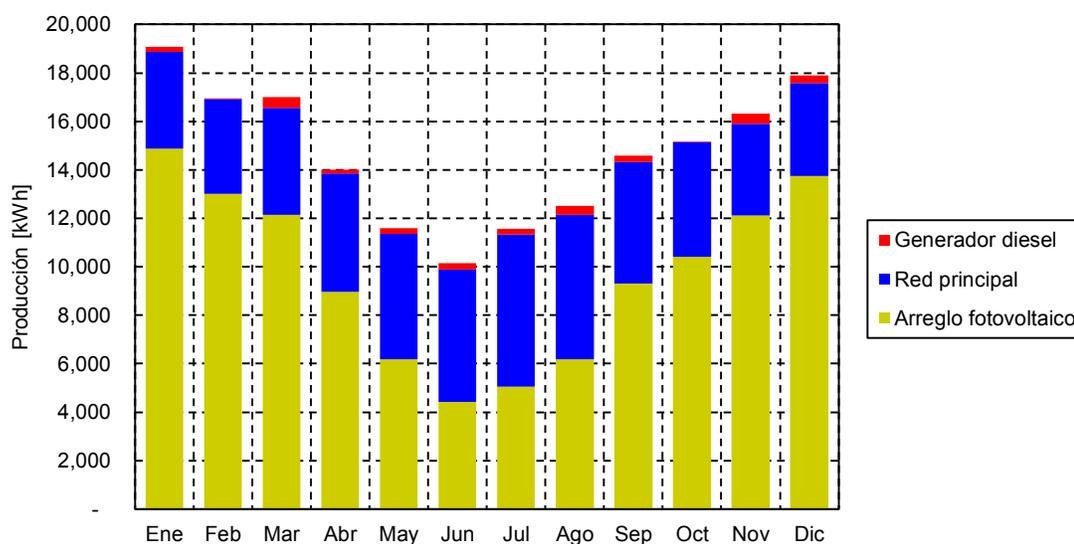


Figura 4.11: Producción mensual promedio de energía.

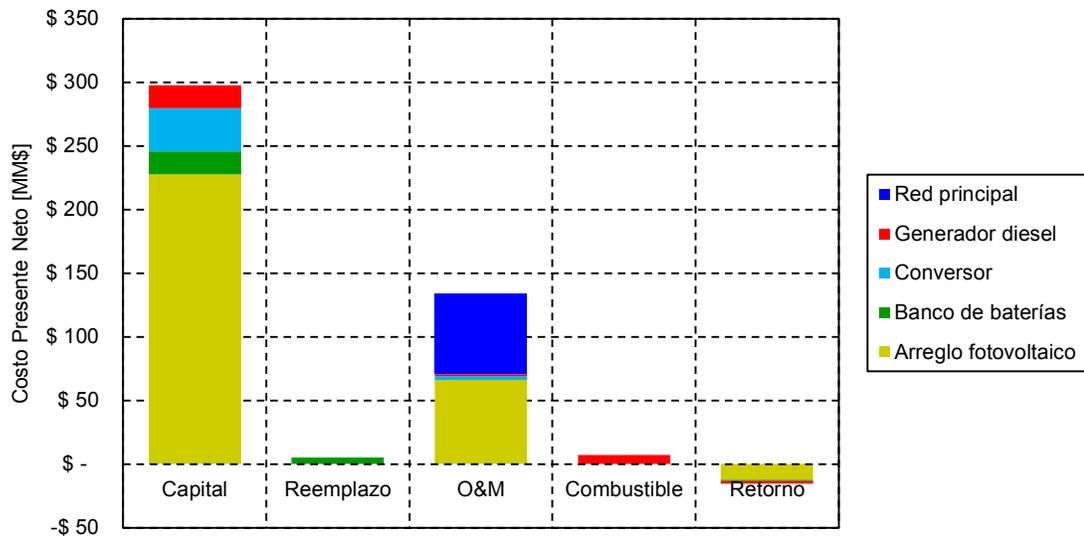


Figura 4.12: Resumen de costos del proyecto.

A partir de los resultados, se tiene que el sistema fotovoltaico es el elemento que implica un mayor costo del proyecto, correspondiente al 76.47% de la inversión total y al 49.23% de los costos de O&M del sistema, sin embargo, es también el elemento con el mayor aporte energético, concentrándose especialmente en los meses de verano, donde la producción en torno a los 14 000 [kWh/mes] genera ventas de excedentes hacia la red.

A continuación, se presenta los resultados del análisis de sensibilidad del diseño de la micro-red obtenida, en función del precio estimado del diésel y del precio (tarifa) de compra de energía desde la red. Este análisis es importante para determinar la modificación del diseño y variaciones en los costos y/u operación del sistema frente a otros escenarios y consideraciones probables que puedan ocurrir en el futuro.

4.3.2. Resultados de análisis de sensibilidad.

Para el estudio y análisis de sensibilidad del diseño, se ha considerado la configuración, costos y resultados de operación obtenida en el “caso desfavorable” descrito en la sección 4.3.1. Para este análisis se han considerado tres escenarios probables:

- **Sin sensibilidad:** corresponde a los resultados del diseño ya obtenidos para el “caso desfavorable”. Este escenario considera un precio del diésel de 399 [\$/lt] y un precio de compra de la energía de 176.83 [\$/kWh].
- **Con alto precio del diésel:** escenario basado en las consideraciones tomadas en el “caso desfavorable”, donde se asume un precio del diésel de 701 [\$/lt], basado su máximo valor histórico de los últimos 2 años.

- **Con equidad tarifaria:** escenario baso en las consideraciones tomadas en el “caso desfavorable”, donde se asume un precio de compra de la energía de 129.26 [\$/kWh] basado en la promulgación de la Ley de Equidad Tarifaria.

Reiterando el procedimiento anterior, se realiza el proceso de optimización mediante el software HOMER, obteniendo así el mismo diseño de la micro-red en los tres escenarios considerados, es decir, una configuración compuesta por un arreglo fotovoltaico de 90 [kW], un banco de 36 baterías, un conversor de 80 [kW] y un generador diésel de 20 [kW]. De esta forma, es posible deducir que la planificación del sistema energético es una función inelástica del precio del diésel y del precio de compra de energía. Al obtener la misma configuración en los tres casos analizados, se tiene también la misma operación (presentada para el “caso desfavorable” de la Tabla 4.7), sin embargo, los costos presentados en la Tabla 4.8. son dependientes del caso analizado.

Tabla 4.8: Sensibilidad en los costos asociados a la micro-red.

Costos	Unidad	Sin sensibilidad	Con alto precio del diésel	Con equidad tarifaria
Costo Presente Neto	[MMS\$]	424.87	427.98	396.07
Costos anualizados	[MMS\$/año]	12.94	13.23	10.33
Costo de la Energía	[\$/kWh]	69.61	71.31	53.88

Con respecto a la sensibilidad en el precio del diésel, al considerar un precio más alto aumenta el CPN del proyecto a la vez del CoE, como consecuencia directa de un mayor costo anual del sistema, debido a un aumento en un 75.96% en los costos de combustible, para un mismo consumo de diésel. Por otro lado, respecto a la sensibilidad en el precio de compra de la energía, al considerar un precio más bajo, disminuye el CPN del proyecto a la vez del CoE, como consecuencia de un menor costo de O&M anual del sistema, debido a una reducción del 45.57% en la operación de la red principal (compra de energía).

Finalmente, se presenta a continuación el detalle de la operación simulada de cada componente de la configuración obtenida de la micro-red.

4.3.3. Operación del sistema.

En la Figura 4.13 se presenta la producción durante un año completo del sistema fotovoltaico de 90 [kW] de potencia nominal, donde es posible observar la dependencia de la radiación disponible, en función de las horas de sol y también del efecto de la nubosidad. El factor de planta del sistema fotovoltaico es de 14.77%, operando a una potencia promedio de 13 [kW] y una generación energética promedio de 318.93 [kWh/día] (considerando noche), alcanzando una potencia máxima de 70.55 [kW].

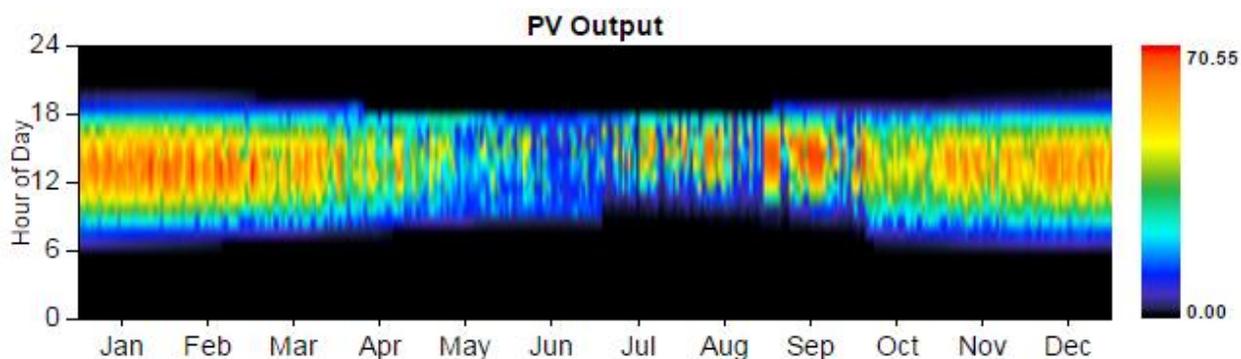


Figura 4.13: Producción anual del sistema fotovoltaico.

La Figura 4.14 presenta la producción anual del generador diésel de 20 [kW] de potencia nominal, donde es posible observar que su operación se limita únicamente a cubrir las fallas que ocurren en la red principal, presentadas en la Figura 4.5. En esta simulación, el generador diésel arranca 41 veces por año, con una potencia mínima de 5 [kW], una potencia máxima de 17 [kW] y consecuentemente, una potencia promedio de 9 [kW].

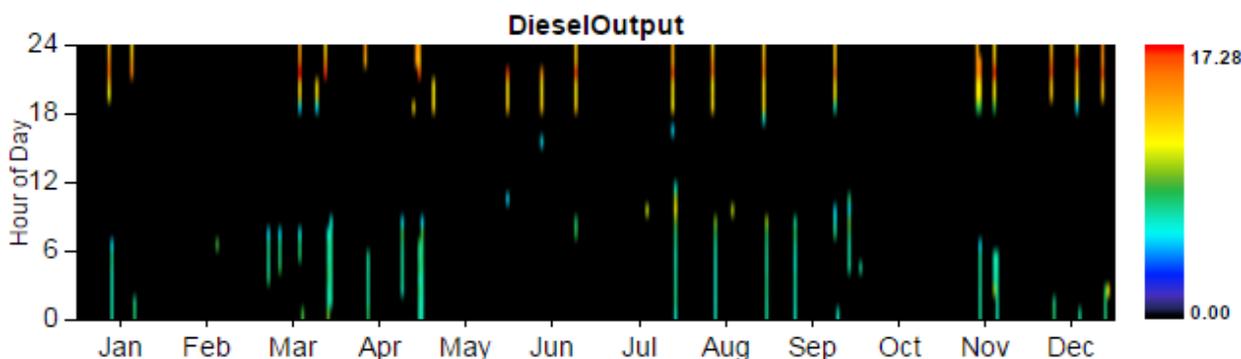


Figura 4.14: Producción anual del generador diésel.

La Figura 4.15 presenta las compras anuales desde la red principal, que ocurren principalmente en horas de noche; mientras que la Figura 4.16 presenta las ventas hacia la red, que se concentran a medio día. Es posible observar también el efecto de la disponibilidad/indisponibilidad de la red, ya que cuando ocurren los cortes de suministro (no programadas), no es posible intercambio de energía entre la micro-red y la red eléctrica principal. Por otro lado, es posible notar que, en condiciones de días invernales con baja radiación y alta nubosidad, la demanda eléctrica a medio día no es totalmente abastecida por el sistema fotovoltaico de la micro-red, por lo que es necesario realizar compras adicionales de energía desde la red principal para cubrir el total de la demanda.

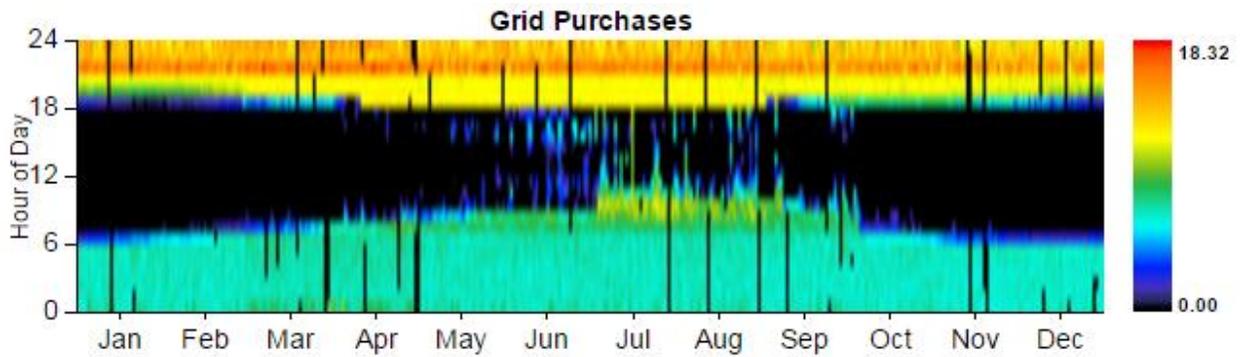


Figura 4.15: Compras anuales desde la red.

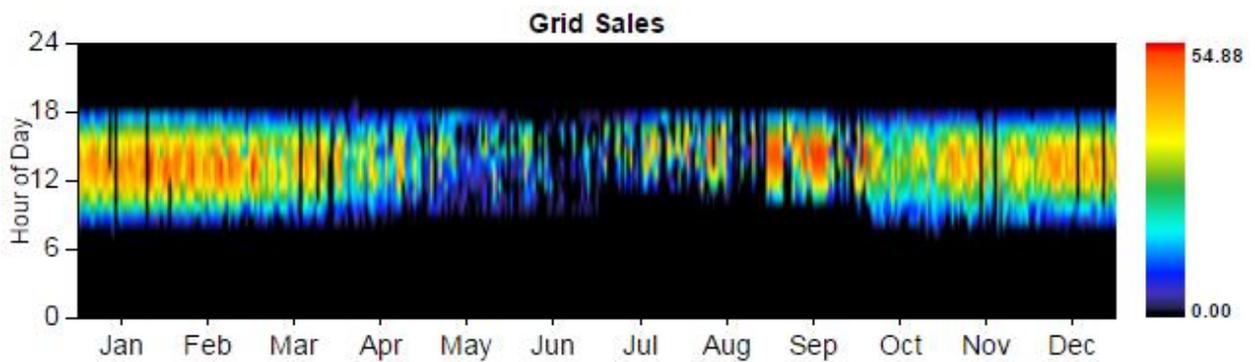


Figura 4.16: Ventas anuales hacia la red.

4.4. Discusión.

En general, en un estudio de evaluación de proyecto se busca obtener la solución que maximice las utilidades percibidas por el inversionista, o bien, que minimice su costo. En este capítulo se ha presentado la metodología de planificación de micro-redes con un nuevo criterio que busca minimizar el costo de la energía percibido por los miembros de una comunidad bajo el enfoque de un proyecto social, y que privilegie la inserción de tecnologías con bajo costo de operación, como lo son aquellas basadas en fuentes renovables.

Las variables que mayor influencia tienen en la obtención del diseño final del sistema son, por una parte, la disponibilidad de los recursos renovables (eólico y solar) y el nivel de demanda eléctrica, pero también son los costos asociados de inversión y de O&M de cada tecnología, ya que, por ejemplo, como es el caso de la tecnología eólica, a pesar de las buenas condiciones del recurso eólico en la localidad de estudio, su alto costo asociado implica que no sea una alternativa viable en la planificación de la micro-red.

El diseño obtenido es óptimo para una gran parte de escenarios esperados, permitiendo una menor dependencia de la red eléctrica principal.

Capítulo 5. Conclusiones y trabajo futuro.

5.1. Conclusiones generales.

En este trabajo se analizaron distintos escenarios para la planificación de una micro-red conectada a la red principal en la comunidad Mapuche rural de José Painecura Hueñalihuen. Los escenarios generados utilizando modelos de intervalos para el recurso eólico, el recurso solar y demanda eléctrica permiten caracterizar dichas variables a través de una banda que contiene los valores medidos con un cierto nivel de confianza.

Con respecto al trabajo de modelación lineal y difusa de T&S, en el análisis de la velocidad del viento se obtiene un desempeño similar en ambos modelos identificados, mientras que, en el estudio de la radiación solar, no fue posible obtener un modelo difuso estable con los datos disponibles. Por otro lado, en el estudio de demanda eléctrica se obtuvo un mejor desempeño al representar su comportamiento mediante modelación difusa.

En función de los resultados obtenidos en la identificación de modelos de intervalos, se obtiene que el recurso eólico presenta una mayor incertidumbre que el recurso solar, mientras que la demanda eléctrica se encuentra correctamente identificada a través de sus modelos de intervalos, presentado los mejores resultados en sus índices de desempeño a 1 paso y 24 pasos de predicción. De esta forma, se deduce que el recurso eólico es la principal fuente de variabilidad de escenarios generados para el proceso de planificación de la micro-red.

En relación a la demanda eléctrica, se desarrolló un simulador de consumo basado en la información socio-demográfica recopiladas en encuestas realizadas a toda la comunidad, y en datos de demanda medidos en un periodo de tiempo reducido en algunos hogares, escogidos mediante el algoritmo no supervisado de agrupación SOM. A través de realizaciones de cadenas de Markov, se obtiene un perfil de demanda eléctrica total de la comunidad para todo un año, que mantiene las características generales con respecto a las mediciones realizadas por la empresa distribuidora, pero que es lo suficientemente variable como para simular distintas condiciones de consumo en la planificación de la micro-red.

Basado en los escenarios generados derivado de los intervalos resultantes, y considerando criterios técnico-económicos, se obtienen diferentes topologías de diseño de micro-redes apropiadas para el caso de estudio. La elección del diseño final consiste en tomar el peor escenario derivado de los intervalos resultantes, es decir, subestimando el recurso eólico y sobrestimando la demanda eléctrica, donde el riesgo de la inversión es menor. Bajo este criterio conservador, se privilegia la tecnología de generación fotovoltaica por sobre la generación eólica, pues se dispone de condiciones aptas de radiación. La menor inversión por kilowatt de un sistema fotovoltaico con respecto a un aerogenerador responde a una menor dificultad en el transporte e instalación en una comunidad aislada, mientras que su menor costo de O&M se debe a que es posible prescindir de personal técnico para el mantenimiento rutinario del sistema.

Finalmente, el diseño de la micro-red obtenido es óptimo para un rango de valores probables del precio del diésel y del precio de compra de energía. Con respecto a la operación estimada, se espera una producción del sistema fotovoltaico con un factor de planta cercano a un 15%; una operación

del generador diésel solo en momentos de contingencia apoyado por el banco de baterías para realizar una transición suave de la operación conectada a la red al modo isla de la micro-red; y un flujo de potencia desde la micro-red hacia la red principal durante el día, y un flujo con sentido inverso durante la noche.

5.2. Líneas de investigación futuras.

Como trabajo futuro se propone lo siguiente:

- Replantear el problema de identificación de parámetros de premisas y consecuencias de un modelo difuso como un único problema de optimización, de forma de obtener un modelo óptimo global que presente un mejor desempeño que los modelos identificados con el método propuesto en la sección 2.3.
- Adaptar la metodología de generación de perfiles aleatorios presentado en la sección 2.7.2. de manera que las probabilidades iniciales de estado p_i depende de los datos del grupo q anterior.
- Incluir un enfoque de optimización multiobjetivo que permita la ampliación del análisis, incluyendo el impacto ambiental y social dentro de la función objetivo.

5.3. Publicaciones generadas.

En el contexto del presente trabajo de tesis se ha generado las siguientes publicaciones:

- R. Morales, D. Sáez, L. G. Marín, and A. Nuñez, “Microgrid Planning based on Fuzzy Interval Models of Renewable Resources,” in IEEE World Congress on Computational Intelligence, 2016, p. 8.
- J. Llanos, R. Morales, A. Nuñez, D. Sáez, M. Lacalle, L. G. Marín, R. Hernández, and F. Lanás, “Load Estimation for Microgrid Planning based on a Self-Organizing Map Methodology,” Appl. Soft Comput., 2016.
- C. Vargas, R. Morales, D. Sáez, R. Hernández, C. Muñoz, J. Huircán, E. Espina, C. Alarcón, V. Caquilpan, N. Painemal, and R. Cárdenas, “Design of a Participatory-Model/Microgrid/Smart-Farm System for Indigenous Mapuche Communities,” J. Rural Stud., 2016.

Bibliografía.

- [1] A. Niez, *Comparative Study on Rural Electrification Policies in Emerging Economies: Keys to Successful Policies*. Paris: OECD/IEA, 2010.
- [2] M. G. Pereira, M. A. V. Freitas, and N. F. da Silva, “Rural electrification and energy poverty: Empirical evidences from Brazil,” *Renew. Sustain. Energy Rev.*, vol. 14, no. 4, pp. 1229–1240, May 2010.
- [3] L. Ferrer-Martí, A. Garwood, J. Chiroque, B. Ramirez, O. Marcelo, M. Garfí, and E. Velo, “Evaluating and comparing three community small-scale wind electrification projects,” *Renew. Sustain. Energy Rev.*, vol. 16, no. 7, pp. 5379–5390, Sep. 2012.
- [4] Centro de Energía FCFM, “Micro-redes para localidades aisladas,” Santiago, 2013.
- [5] F. Covarrubias, I. Irrarrázaval, and R. Galáz, “Desafíos de la Electrificación Rural en Chile,” *Programa Asist. a la Gestión del Sect. la Energía*, p. 114, 2005.
- [6] E. Baldwin, J. N. Brass, S. Carley, and L. M. MacLean, “Electrification and rural development: issues of scale in distributed generation,” *Wiley Interdiscip. Rev. Energy Environ.*, vol. 4, no. 2, pp. 196–211, 2015.
- [7] K. Ubilla, G. A. Jimenez-Estevez, R. Hernandez, L. Reyes-Chamorro, C. Hernandez Irigoyen, B. Severino, and R. Palma-Behnke, “Smart Microgrids as a Solution for Rural Electrification: Ensuring Long-Term Sustainability Through Cadastre and Business Models,” *IEEE Trans. Sustain. Energy*, vol. 5, no. 4, pp. 1310–1318, Oct. 2014.
- [8] J. Leary, A. While, and R. Howell, “Locally manufactured wind power technology for sustainable rural electrification,” *Energy Policy*, vol. 43, pp. 173–183, Apr. 2012.
- [9] R. H. Lasseter, “MicroGrids,” in *2002 IEEE Power Engineering Society Winter Meeting*, 2002, vol. 1, pp. 305–308.
- [10] T. E. Del Carpio Huayllas, D. S. Ramos, and R. . Vasquez-Arnez, “Microgrid systems: Current status and challenges,” in *2010 IEEE/PES Transmission and Distribution Conference and Exposition: Latin America*, 2010, vol. 900, pp. 7–12.
- [11] X. Vallvé, “Micro-grid power systems based on renewable energy for rural electrification: benefits, examples and steps to promote these solutions,” in *International hearing on Climate Change an Energy access for the poor*, 2010, pp. 26–28.
- [12] J. Agredano, J. Huacuz, and G. Munguía, “La electrificación de Puerto Alcatraz, Baja California Sur, México, Un análisis retrospectivo.” 2007.
- [13] Ministerio de Desarrollo Social, “CASEN 2013 Pueblos Indígenas,” 2013.
- [14] A. Deruyttere, “Pueblos indígenas, globalización y desarrollo con identidad: algunas

- reflexiones de estrategia,” *Unidad de Pueblos Indígenas y Desarrollo Comunitario*. p. 15, 2001.
- [15] Z. Ye, R. Walling, N. Miller, P. Du, and K. Nelson, “Facility Microgrids,” Golden, CO, 2005.
- [16] R. H. Lasseter, “Smart distribution: Coupled microgrids,” *Proc. IEEE*, vol. 99, no. 6, pp. 1074–1082, 2011.
- [17] C. Marnay, S. Chatzivasileiadis, C. Abbey, R. Iravani, G. Joos, P. Lombardi, P. Mancarella, and J. von Appen, “Microgrid Evolution Roadmap,” in *International Symposium on Smart Electric Distribution Systems and Technologies (EDST), 2015*, 2015, pp. 139–144.
- [18] U.S. Department of Energy, “DOE Microgrid Workshop Report,” San Diego, California, 2011.
- [19] General Electric Company, “Grid IQ Microgrid Control System,” *Microgrid Overview*. [Online]. Available: <https://www.gegridsolutions.com/multilin/catalog/mcs.htm>. [Accessed: 13-Sep-2016].
- [20] R. J. Campbell, “Weather-Related Power Outages and Electric System Resiliency,” Washington D. C., 2012.
- [21] J. St. John, “How Microgrids Helped Weather Hurricane Sandy,” 2012. [Online]. Available: <http://www.greentechmedia.com/articles/read/how-microgrids-helped-weather-hurricane-sandy>. [Accessed: 13-Sep-2016].
- [22] Microgrids Group at Berkeley Lab, “Types Of Microgrids,” 2014. [Online]. Available: <https://building-microgrid.lbl.gov/types-microgrids>. [Accessed: 13-Sep-2016].
- [23] San Diego Gas & Electric y Southern California Gas Co., “SDG&E Receives \$5 Million Grant to Expand Borrego Springs Microgrid,” 2015. [Online]. Available: <http://www.sdge.com/newsroom/press-releases/2015-02-17/sdge-receives-5-million-grant-expand-borrego-springs-microgrid>. [Accessed: 20-Sep-2016].
- [24] O. Nuñez, D. Ortiz, and R. Palma-Behnke, “Microrredes en la red eléctrica del futuro - caso Huatacondo,” *Rev. Cienc. y Tecnol.*, vol. 29, no. 2, p. 16, 2013.
- [25] N. D. Hatziargyriou, *Microgrids: Architectures and Control*, First Edit. Chichester, UK: John Wiley & Sons, Ltd., 2014.
- [26] L. Qiao, “A Summary of Optimal Methods for the Planning of Stand-alone Microgrid System,” *Energy Power Eng.*, vol. 5, no. 4B, pp. 992–998, 2013.
- [27] M. Kolhe, K. M. I. U. Ranaweera, and A. G. B. S. Gunawardana, “Techno-economic optimum sizing of hybrid renewable energy system,” in *Industrial Electronics Society, IECON 2013 - 39th Annual Conference of the IEEE*, 2013, pp. 1898–1903.

- [28] S. Liu, Z. Wu, X. Dou, B. Zhao, S. Zhao, and C. Sun, "Optimal configuration of hybrid solar-wind distributed generation capacity in a grid-connected microgrid," in *Innovative Smart Grid Technologies (ISGT), 2013 IEEE PES*, 2013, pp. 1–6.
- [29] W. Su, Z. Yuan, and M. Y. Chow, "Microgrid planning and operation: Solar energy and wind energy," in *2010 IEEE Power & Energy Society General Meeting*, 2010, pp. 1–7.
- [30] C. Wang, M. Liu, and L. Guo, "Cooperative operation and optimal design for islanded microgrid," in *2012 IEEE PES Innovative Smart Grid Technologies (ISGT)*, 2012, pp. 1–8.
- [31] X. E. Yu, P. Malysz, S. Sirouspour, and A. Emadi, "Optimal microgrid component sizing using mixed integer linear programming," in *2014 IEEE Transportation Electrification Conference and Expo (ITEC)*, 2014, pp. 1–6.
- [32] S. Chakraborty, T. Senjyu, A. Yona, and T. Funabashi, "Optimal energy storage size of thermal/wind power system using tabu search optimizer," in *2010 9th International Power & Energy Conference*, 2010, pp. 423–428.
- [33] Y. Luo, L. Shi, and G. Tu, "Optimal sizing and control strategy of isolated grid with wind power and energy storage system," *Energy Convers. Manag.*, vol. 80, pp. 407–415, 2014.
- [34] Y. Wang and Y. Zhang, "Optimal algorithm of distribution network planning including distributed generation," in *Third International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, 2008. DRPT 2008*, 2008, pp. 872–876.
- [35] B. Zhao, X. Zhang, P. Li, K. Wang, M. Xue, and C. Wang, "Optimal sizing, operating strategy and operational experience of a stand-alone microgrid on Dongfushan Island," *Appl. Energy*, vol. 113, pp. 1656–1666, 2014.
- [36] A. Khodaei and M. Shahidehpour, "Microgrid-Based Co-Optimization of Generation and Transmission Planning in Power Systems," *IEEE Trans. Power Syst.*, vol. 28, no. 2, pp. 1582–1590, May 2013.
- [37] A. Khodaei, S. Bahramirad, and M. Shahidehpour, "Microgrid planning under uncertainty," *IEEE Trans. Power Syst.*, vol. 30, no. 5, pp. 2417–2425, 2015.
- [38] A. Khodaei, "Provisional Microgrid Planning," *IEEE Trans. Smart Grid*, vol. PP, no. 99, pp. 1–9, 2015.
- [39] L. Guo, W. Liu, B. Jiao, B. Hong, and C. Wang, "Multi-objective stochastic optimal planning method for stand-alone microgrid system," *IET Gener. Transm. Distrib.*, vol. 8, no. 7, pp. 1263–1273, 2014.
- [40] H. K. Alfares and M. Nazeeruddin, "Electric load forecasting: Literature survey and classification of methods," *Int. J. Syst. Sci.*, vol. 33, no. 1, pp. 23–34, Jan. 2002.
- [41] A. Ghanbari, E. Hadavandi, and S. Abbasian-Naghneh, "Comparison of artificial intelligence based techniques for short term load forecasting," in *2010 Third International*

Conference on Business Intelligence and Financial Engineering, 2010, pp. 6–10.

- [42] H. Quan, D. Srinivasan, and A. Khosravi, “Short-term load and wind power forecasting using neural network-based prediction intervals,” *IEEE Trans. Neural Learn. Syst.*, vol. 25, no. 2, pp. 303–315, 2014.
- [43] A. Khosravi, S. Nahavandi, and D. Creighton, “Construction of optimal prediction intervals for load forecasting problems,” *IEEE Trans. Power Syst.*, vol. 25, no. 3, pp. 1496–1503, 2010.
- [44] S. Jafarzadeh, M. S. Fadali, and C. Y. Evrenosoğlu, “Solar power prediction using interval type-2 TSK modeling,” *IEEE Trans. Sustain. Energy*, vol. 4, no. 2, pp. 333–339, 2013.
- [45] J. Xia, P. Zhao, and Y. Dai, “Neuro-fuzzy networks for short-term wind power forecasting,” in *2010 International Conference on Power System Technology*, 2010, pp. 1–5.
- [46] D. Sáez, F. Avila, D. E. Olivares, C. Canizares, and L. G. Marin, “Fuzzy Prediction Interval Models for Forecasting Renewable Resources and Loads in Microgrids,” *IEEE Trans. Smart Grid*, vol. 6, no. 2, pp. 548–556, 2015.
- [47] F. Veltman, L. G. Marin, D. Sáez, L. Guitierrez, and A. Nuñez, “Prediction Interval Modeling Tuned by an Improved Teaching Learning Algorithm Applied to Load Forecasting in Microgrids,” in *2015 IEEE Symposium Series on Computational Intelligence*, 2015, pp. 651–658.
- [48] A. Bayas, “Diseño de Estrategias de Control Difuso Robusto ante Incertidumbre Paramétrica para Plantas de Colectores Solares,” Universidad de Chile, 2016.
- [49] L. Ljung, *System Identification Toolbox: User’s Guide*. Natick, MA: MathWorks, 2014.
- [50] O. Nelles, *Nonlinear system identification: From classical approaches to neural networks and fuzzy models*, 1st ed. Springer Berlin Heidelberg, 2001.
- [51] M. Norgaard, O. Ravn, and N. K. Poulsen, “NNSYSID and NNCTRL tools for system identification and control with neural networks,” *Comput. Control Eng. J.*, vol. 12, no. 1, pp. 29–36, Feb. 2001.
- [52] L. A. Zadeh, “Outline of a New Approach to the Analysis of Complex Systems and Decision Processes,” *IEEE Trans. Syst. Man. Cybern.*, vol. SMC-3, no. 1, pp. 28–44, 1973.
- [53] E. H. Mamdani, “Application of fuzzy algorithms for control of simple dynamic plant,” *Electr. Eng. Proc. Inst.*, vol. 121, no. 12, pp. 1585–1588, 1974.
- [54] T. Takagi and M. Sugeno, “Fuzzy identification of systems and its applications to modeling and control,” *Syst. Man Cybern. IEEE Trans.*, vol. SMC-15, no. 1, pp. 116–132, 1985.
- [55] D. Sáez, F. Avila, J. Collado, L. Gutierrez, and L. G. Marín, “Modelación Difusa: Apuntes EL7012 - Control Inteligente de Sistemas,” Santiago, Chile, 2016.

- [56] L. X. Wang and J. M. Mendel, "Fuzzy basis functions, universal approximation, and orthogonal least-squares learning," *IEEE Trans. Neural Networks*, vol. 3, no. 5, pp. 807–814, Sep. 1992.
- [57] M. Norgaard, O. E. Ravn, N. K. Poulsen, and L. K. Hansen, *Neural Networks for Modelling and Control of Dynamic Systems: A Practitioner's Handbook*, 1st ed. Secaucus, NJ, USA: Springer-Verlag New York, Inc., 2000.
- [58] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 2nd ed., vol. 1. New York, NY: Springer-Verlag New York, 2009.
- [59] MathWorks, "Divide Data for Optimal Neural Network Training," 2015. [Online]. Available: <http://www.mathworks.com/help/nnet/ug/divide-data-for-optimal-neural-network-training.html>. [Accessed: 29-Sep-2016].
- [60] H. Akaike, "A new look at the statistical model identification," *IEEE Trans. Automat. Contr.*, vol. 19, no. 6, pp. 716–723, 1974.
- [61] M. Sugeno and T. Yasukawa, "A fuzzy-logic-based approach to qualitative modeling," *IEEE Trans. Fuzzy Syst.*, vol. 1, no. 1, pp. 7–31, Feb. 1993.
- [62] L. Ljung, *System Identification: Theory for the User*, 1st ed. New Jersey, NJ: Prentice Hall, 1987.
- [63] D. Saez and R. Zuñiga, "Cluster optimization for Takagi & Sugeno fuzzy models and its application to a combined cycle power plant boiler," in *Proceedings of the 2004 American Control Conference*, 2004, vol. 2, pp. 1776–1781.
- [64] S. Alimi and M. Chtourou, "Stability Analysis of Fuzzy Identification for Nonlinear Discrete Systems - Part I: Theoretical Study," in *2009 Second International Conference on Developments in eSystems Engineering (DESE)*, 2009, pp. 349–353.
- [65] K. M. Pekpe, J.-P. Cassar, and S. Chenikher, "Identification of MIMO Takagi-Sugeno model of a bioreactor," in *2007 IEEE International Fuzzy Systems Conference*, 2007, pp. 1–6.
- [66] L. Wang and R. Langari, "A decomposition approach for fuzzy systems identification," in *Proceedings of the 34th IEEE Conference on Decision and Control*, 1995, vol. 1, pp. 261–266.
- [67] R. Babuška, *Fuzzy Modeling for Control*, 1st ed. Norwell, MA: Springer Netherlands, 1998.
- [68] J. C. Bezdek, C. Coray, R. Gunderson, and J. Watson, "Detection and Characterization of Cluster Substructure I. Linear Structure: Fuzzy c-Lines," *SIAM J. Appl. Math.*, vol. 40, no. 2, pp. 339–357, 1981.
- [69] E. H. Ruspini, "Numerical methods for fuzzy clustering," *Inf. Sci. (Ny)*, vol. 2, no. 3, pp.

319–350, 1970.

- [70] D. E. Gustafson and W. C. Kessel, “Fuzzy clustering with a fuzzy covariance matrix,” in *1978 IEEE Conference on Decision and Control including the 17th Symposium on Adaptive Processes*, 1978, pp. 761–766.
- [71] K. Ogata, *Ingenieria de control moderna*, 5th ed. Madrid, España: PEARSON, 2010.
- [72] K. Tanaka and M. Sugeno, “Stability analysis and design of fuzzy control systems,” *Fuzzy Sets Syst.*, vol. 45, no. 2, pp. 135–156, 1992.
- [73] K. Tanaka and M. Sano, “On the concepts of regulator and observer of fuzzy control systems,” in *Proceedings of the Third IEEE Conference on Fuzzy Systems: IEEE World Congress on Computational Intelligence*, 1994, pp. 767–772.
- [74] H. Zou, J. Lei, and H. Yu, “Extended Lyapunov Stability Theorem and Its Applications in Control System with Constrained Input,” in *2009 International Symposium on Computer Network and Multimedia Technology*, 2009, pp. 1–4.
- [75] H. K. Khalil, *Nonlinear Systems*, 3rd ed. Prentice Hall, 2002.
- [76] I. Škrjanc, S. Blažič, and O. Agamennoni, “Identification of dynamical systems with a robust interval fuzzy model,” *Automatica*, vol. 41, no. 2, pp. 327–332, 2005.
- [77] I. Škrjanc, “Fuzzy confidence interval for pH titration curve,” *Appl. Math. Model.*, vol. 35, no. 8, pp. 4083–4090, Aug. 2011.
- [78] I. Škrjanc, “Confidence interval of fuzzy models: An example using a waste-water treatment plant,” *Chemom. Intell. Lab. Syst.*, vol. 96, no. 2, pp. 182–187, 2009.
- [79] T. Kohonen, “The self-organizing map,” *Proc. IEEE*, vol. 78, no. 9, pp. 1464–1480, Sep. 1990.
- [80] T. Kohonen, S. Kaski, K. Lagus, J. Salojarvi, J. Honkela, V. Paatero, and A. Saarela, “Self organization of a massive document collection,” *IEEE Trans. Neural Networks*, vol. 11, no. 3, pp. 574–585, May 2000.
- [81] S. Valero, J. Aparicio, C. Senabre, M. Ortiz, J. Sancho, and A. Gabaldon, “Comparative analysis of self organizing maps vs. multilayer perceptron neural networks for short-term load forecasting,” in *2010 Proceedings of the International Symposium Modern Electric Power Systems (MEPS)*, 2010, pp. 1–5.
- [82] G. Dreyfus, *Neural Networks: Methodology and Applications*. Springer-Verlag Berlin Heidelberg, 2005.
- [83] J. Kangas and T. Kohonen, “Developments and applications of the self-organizing map and related algorithms,” *Math. Comput. Simul.*, vol. 41, no. 1–2, pp. 3–12, Jun. 1996.
- [84] J. C. Patra, E. L. Ang, P. K. Meher, and Q. Zhen, “A New SOM-based Visualization

Technique for DNA Microarray Data,” in *2006 International Joint Conference on Neural Networks*, 2006, pp. 4429–4434.

- [85] D. A. Levin, Y. Peres, and E. L. Wilmer, *Markov Chains and Mixing Times*. Providence, RI: American Mathematical Society, 2009.
- [86] T. W. Anderson and L. A. Goodman, “Statistical Inference about Markov Chains,” *Ann. Math. Stat.*, vol. 28, no. 1, pp. 89–110, 1957.
- [87] H. Navarrete, “Caracterización estadística del perfil de uso de baterías para el pronóstico de estado de carga,” Universidad de Chile, 2014.
- [88] T. Roje, “Diseño de estrategia de control para gestión de demanda de micro-redes aisladas,” Universidad de Chile, 2015.
- [89] C. Vargas, “Propuesta metodológica sobre la selección de comunidades rurales aisladas, para la inserción de un proyecto de micro-red, utilizando criterios socio-ambientales,” Universidad de Chile, 2015.
- [90] R. Hernández and C. Vargas, “Micro-redes en comunidades indígenas de Chile: análisis antropológico de estas experiencias,” *Rev. Márgenes, Univ. Valparaíso*, vol. 12, no. 17, p. 17, 2016.
- [91] J. M. Wallace and P. V. Hobbs, *Atmospheric Science*, Second Edi. Washington, USA: Elsevier, 2006.
- [92] R. Rioseco and T. Claudio, “Cartografía Interactiva de los climas de Chile,” 2006. [Online]. Available: www.uc.cl/sw_educ/geografia/cartografiainteractiva. [Accessed: 02-Mar-2016].
- [93] F. Santibañez and J. Uribe, *Atlas agroclimático de Chile: regiones Sexta, Séptima, Octava y Novena*. Santiago, Chile: Universidad de Chile, 1993.
- [94] V. Caquilpan, “Estimación de la demanda eléctrica y potencial energético de recursos renovables para el diseño de micro-redes en comunidades rurales,” Universidad de Chile, 2016.
- [95] I. Richardson, M. Thomson, D. Infield, and C. Clifford, “Domestic electricity use: A high-resolution energy demand model,” *Energy Build.*, vol. 42, no. 10, pp. 1878–1887, Oct. 2010.
- [96] Y. Yamaguchi, T. Fujimoto, and Y. Shimoda, “Occupant behavior model for households to estimate high-temporal resolution residential electricity demand profile,” in *12th Conference of International Building Performance Simulation Association*, 2011, pp. 1548–1555.
- [97] J. Llanos, D. Sáez, R. Palma-Behnke, A. Núñez, and G. Jiménez-Estévez, “Load profile generator and load forecasting for a renewable based microgrid using Self Organizing Maps and neural networks,” in *IEEE World Congress on Computational Intelligence*, 2012, p. 8.

- [98] A. Calvo, A. Tartakowsky, and T. Maffei, “Transformaciones en las Estructuras Familiares en Chile,” Santiago, Chile, 2011.
- [99] NREL National Renewable Energy Laboratory, “Getting Started Guide for HOMER Version 2.1.” Golden, Colorado, p. 30, 2005.
- [100] J. A. Duffie and W. A. Beckman, *Solar Engineering of Thermal Processes*, 4th ed. Hoboken, NJ: John Wiley & Sons, Inc., 2013.
- [101] G. M. Masters, *Renewable and Efficient Electric Power Systems*, 1st ed. Hoboken, NJ: John Wiley & Sons, Inc., 2004.
- [102] D. G. Erbs, S. A. Klein, and J. A. Duffie, “Estimation of the diffuse radiation fraction for hourly, daily and monthly-average global radiation,” *Sol. Energy*, vol. 28, no. 4, pp. 293–302, 1982.
- [103] Homer Energy, “HOMER® Pro V3.7 User Manual,” Boulder, CO, 2016.
- [104] J. F. Manwell and J. G. McGowan, “Lead acid battery storage model for hybrid energy systems,” *Sol. Energy*, vol. 50, no. 5, pp. 399–405, 1993.
- [105] Instituto de Asuntos Públicos de la (UCHile) and Centro de Innovación en Energía (UTFSM), “Aporte potencial de Energías Renovables No Convencionales y Eficiencia Energética a la Matriz Eléctrica, 2008-2025,” 2008.
- [106] Global-rates, “Inflación Chile - índice de precios al consumo (IPC),” *IPC CL últimos años*, 2016. [Online]. Available: <http://es.global-rates.com/estadisticas-economicas/inflacion/indice-de-precios-al-consumo/ipc/chile.aspx>. [Accessed: 07-Oct-2016].
- [107] Ministerio de Energía, “Reglamento de la Ley N° 20.521,” Santiago, Chile, 2014.
- [108] Empresa Eléctrica de la Frontera S.A., “Tarifas de Suministro Eléctrico,” Osorno, Chile, 2016.
- [109] Gobierno de Chile, “Ley de Equidad Tarifaria en Servicios Eléctricos: la normativa que favorece el pago de una cuenta justa,” 2016. [Online]. Available: <http://www.gob.cl/promulgacion-ley-equidad-tarifaria-servicios-electricos/>. [Accessed: 16-Jan-2016].
- [110] Intertek Testing and Certification Ltd., “Wind Turbine Generator System AWEA Summary Test Report,” 2013.
- [111] Enair Energy S.L., “Manual de usuario - Aerogeneradores 30 y 70,” Alicante, España.
- [112] Danish Wind Industry Association, “Costes de operación y mantenimiento en aerogeneradores,” 2003. [Online]. Available: http://www.motiva.fi/myllarin_tuulivoima/windpower_web/es/tour/econ/oandm.htm.

[Accessed: 09-Jan-2017].

- [113] CanadianSolar, “Datasheet CS6P,” San Ramon, CA, 2013.
- [114] C. Breyer, A. Gerlach, J. Mueller, H. Behacker, and A. Milner, “Grid-Parity Analysis for EU and US Regions and Market Segments - Dynamics of Grid-Parity and Dependence on Solar Irradiance, Local Electricity Prices and PV Progress Ratio,” in *European Photovoltaic Solar Energy Conference*, 2009, no. 24th, pp. 4492–4500.
- [115] Victron Energy, “Datasheet Inversor/cargador MultiPlus,” Almere, Netherlands.
- [116] SOLARshop.cl, “Inversores cargadores (UPS),” 2016. [Online]. Available: http://www.solarshop.cl/category.php?id_category=85. [Accessed: 12-Jan-2017].
- [117] AquitoSolar, “Batería ciclo profundo 12V 100Ah Ultracell UC10012 AGM,” 2016. [Online]. Available: <http://www.aquitosolar.cl/baterias-energia-solar/561-UC10012.html>. [Accessed: 12-Jan-2017].
- [118] M. Arriaga, C. A. Canizares, and M. Kazerani, “Renewable Energy Alternatives for Remote Communities in Northern Ontario, Canada,” *Sustain. Energy, IEEE Trans.*, vol. 4, no. 3, pp. 661–670, 2013.
- [119] Universidad de Magallanes, “Informe estudio de factibilidad técnico económica del proyecto de electrificación rural para Villa Tehuelches,” Punta Arenas, Chile, 2006.
- [120] Kipor, “Manual de Operación Grupo Electrónico KDE45SS3, KDE60SS3,” Santiago, 2011.
- [121] L. Giangrandi, “Aspectos técnicos económicos para evaluación de proyectos de cogeneración en base a grupos generadores diesel,” Pontificia Universidad Católica de Chile, 2011.
- [122] Socimac, “Generadores,” 2016. [Online]. Available: <http://www.sodimac.cl/sodimac-cl/category/scat621120/Generadores/>. [Accessed: 13-Jan-2017].
- [123] Comisión Nacional de Energía, “Sistema de Información en Línea de Precios de Combustibles en Estaciones de Servicio,” 2016. [Online]. Available: <http://www.bencinaenlinea.cl/web2/buscador.php?region=11>. [Accessed: 06-Oct-2016].
- [124] ENAP, “Inversionistas y Mercado,” *Tabla de precios de paridad*, 2016. [Online]. Available: http://www.enap.cl/pag/66/991/tabla_de_precios_de_paridad. [Accessed: 25-Aug-2016].
- [125] H. Guglielmetti and C. Covarrubias, “Papa temprana y de guarda: densidad de siembra,” *La Platina*, no. 45, pp. 22–26, 1988.
- [126] Centro de Agua para la Agricultura, “Boletín Técnico N°1 - Necesidades de agua de los cultivos,” Concepción, Chile, 2012.
- [127] Centro de Agricultura y Medioambiente, “Evapotranspiración de referencia para la

determinación de las demandas de riego en Chile,” Santiago, Chile, 2015.

- [128] L. G. James, *Principles of farm irrigation system design*. Krieger Pub Co, 1988.
- [129] A. A. Millar, *Manejo de agua y producción agrícola*, 1st ed. Santiago, Chile: IICA, 1993.
- [130] B. A. Stewart and D. R. Nielsen, *Irrigation of agricultural crops*. Madison, WI, 1990.
- [131] Centro Tecnológico de Suelos y Cultivos - Universidad de Talca, “Mapas de Suelos y Climas,” *Series de Suelos - IX Región de la Araucanía*, 2016. [Online]. Available: <http://www.ctsyc.cl/>. [Accessed: 02-Jan-2017].
- [132] Centro de Información de Recursos Naturales, *Descripciones de suelos materiales y símbolos*. Santiago, Chile, 2002.
- [133] Ebara, “CDX(L)-CD - Centrífuga monocelular - AISI 304 / 316 (L),” 2015. [Online]. Available: <http://www.ebara.es/productos/bombas-centrifugas-horizontales/cdx-cd/>. [Accessed: 04-Jan-2017].
- [134] M. Mitchell, “Elements of Generic Algorithms,” in *An Introduction to Generic Algorithms*, London, UK: The MIT Press, 1998, p. 158.
- [135] J. MacQueen, “Some methods for classification and analysis of multivariate observations,” in *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1967, pp. 281–297.

Anexos.

El presente capítulo contiene información complementaria y detalle de algunos resultados obtenidos en el desarrollo descrito en los capítulos centrales que componen el estudio del trabajo de tesis.

Anexo A. Algoritmos.

A continuación, se presenta el procedimiento de algunos algoritmos relevantes utilizados en el presente trabajo de investigación.

A.1. Algoritmo genético.

Los algoritmos genéticos (*Generic Algorithms*) son algoritmos evolutivos basados en la biología y que tienen su principal aplicación en la búsqueda de parámetros en los procesos de optimización de funciones [134]. La ventaja comparativa que presenta este método frente a otros radica en que es menos probable que se obtenga como solución un máximo local, dado los términos estocásticos que son parte del algoritmo.

El proceso comienza con una población de cromosomas (individuos) dada, definiendo a un cromosoma como un vector de valores binarios (secuencia) que representan los parámetros de la función. Si el problema de optimización es de parámetros reales, es necesario traducir estos valores a un sistema binario. Por su parte, cada cromosoma tiene asociado una función objetivo “*fitness*”, que es evaluada con los parámetros de dicho cromosoma.

Los principales operadores del algoritmo son:

- **Selección:** Se elige un par de cromosomas de la población para su reproducción. Mientras mejor sea la evaluación de su función *fitness*, tendrá más probabilidad de ser seleccionado.
- **Crossover:** Principal motor de búsqueda, donde se recombinan distintas sub-secciones de los cromosomas padres seleccionados.
- **Mutación:** Aleatoriamente, y con baja probabilidad, se cambia un bit del cromosoma.

El procedimiento de un algoritmo genético se puede resumir en los siguientes pasos, donde cada iteración consiste en una nueva “generación” de la población de cromosomas:

1. Crear aleatoriamente n_c cromosomas iniciales.
2. Calcular la función *fitness* para cada cromosoma.
3. Obtener una nueva población:

- 3.1. Seleccionar un par de padres de la población actual de acuerdo a la evaluación de su función *fitness* (selección proporcional).
- 3.2. Recombinar, con probabilidad p_c , las sub-secciones de los cromosomas padres, definidas por uno o varios puntos.
- 3.3. Mutar cromosomas hijos, con probabilidad p_h .
- 3.4. Repetir el proceso desde el paso 3.1. si existe parte de la población con buena evaluación de la función *fitness* no se ha recombinado aún.
4. Reemplazar la población actual por la población nueva.
5. Repetir el procedimiento desde el paso 2.

El algoritmo finaliza al cumplir un cierto criterio de término, como una cantidad definida de generaciones o una tolerancia máxima de la variación en la función *fitness* entre las dos últimas iteraciones. El resultado final corresponderá al cromosoma con mejor función *fitness* de la última generación.

A.2. Algoritmo *k-means*.

K-means [135] es uno de los algoritmos de aprendizaje no supervisado más simples que resuelven el problema de agrupación. El procedimiento iterativo consiste en clasificar un determinado conjunto de n datos u observaciones en exactamente k grupos determinados a priori, definiendo su centroide para cada uno de ellos, con $n \geq k$. El algoritmo busca encontrar las agrupaciones que minimizan la distancia (por ejemplo, euclidiana) entre los puntos pertenecientes a un mismo *cluster* de acuerdo a la expresión (A.1).

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

Donde $\|\cdot\|$ es la medida de distancia, μ_i es la media entre todos los $x \in S_i$ y que corresponde al centroide.

El procedimiento consiste en los siguientes pasos:

1. Elegir k centroides iniciales aleatoriamente en el espacio.
2. Calcular las distancias de cada observación al centroide.
3. Asignar las observaciones. Es posible seguir dos métodos para esto:
 - a. **Batch:** Asigna las observaciones al *cluster* más cercano.

- b. **Online:** Individualmente se 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 el proceso desde el paso 2.

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.

Anexo B. Resultados en identificación de modelos.

El presente anexo corresponde a información complementaria a las secciones 3.4.1. , 3.5.1. y 3.6.4. donde se presenta en detalle parte de los resultados obtenidos en el proceso de identificación de los modelos del recurso eólico, del recurso solar y de la demanda eléctrica, respectivamente.

B.1. Resultados en análisis de estabilidad.

A continuación, se presenta la norma de los polos obtenidos del proceso de análisis de estabilidad de la sección 2.3.6. de los modelos lineales y difusos identificados.

Para el recurso eólico, los polos resultantes del proceso de estabilidad se presentan en la Tabla A.1, mientras que para el recurso solar y demanda eléctrica se presentan en las Tabla A.2 y Tabla A.3, respectivamente.

Tabla A.1: Norma de los polos en modelos del recurso eólico.

Raices	Lineal A_1	Difuso A_1	Difuso A_2	Difuso $A_1 A_2$
1	0.9442	0.8822	0.8378	0.7257
2	0.8906	0.9812	0.9263	0.8526
3	0.8084	0.9812	0.9263	0.8526
4 & 5	0.9571	0.9654	0.9321	0.8655
6 & 7	0.9346	0.9560	0.9319	0.8379
8 & 9	0.9266	0.9500	0.9295	0.8765
10 & 11	0.9282	0.9445	0.9256	0.8213
12 & 13	0.9126	0.9386	0.9207	0.8856
14 & 15	0.9047	0.9322	0.9146	0.8020

16 & 17	0.9088	0.9249	0.9073	0.8940
18 & 19	0.9074	0.9166	0.8983	0.7785
20 & 21	0.8896	0.9070	0.8869	0.9045
22 & 23	0.8737	0.8965	0.8718	0.7487
24 & 25	0.8591	0.8867	0.8516	0.9207

Tabla A.2: Norma de los polos en modelos del recurso solar.

Raices	Lineal A_1	Difuso A_1	Difuso A_2	Difuso A_1A_2
1	0.9069	1.0003	0.9677	0.9619
2	0.9938	0.5970	0.6742	0.3831
3	0.6763	0.6581	0.6715	0.4512
4 & 5	0.9135	1.0028	0.9731	0.8966
6 & 7	0.9349	0.9711	0.9782	0.9283
8 & 9	0.9394	0.9175	0.9777	0.8633
10 & 11	0.9322	0.9325	0.9693	0.9120
12 & 13	0.9392	0.9560	0.9638	0.8489
14 & 15	0.9377	0.9374	0.9594	0.8991
16 & 17	0.9489	0.9020	0.9579	0.8993
18 & 19	0.9547	0.9068	0.9494	0.9586
20 & 21	0.9541	0.9459	0.9387	0.9694
22 & 23	0.9945	0.9159	0.9219	0.8234
24 & 25	0.9977	0.8125	0.9049	0.7551

Tabla A.3: Norma de los polos en modelos de demanda eléctrica.

Raices	Lineal A_1	Difuso A_1	Difuso A_2	Difuso A_3	Difuso A_1A_2	Difuso A_2A_3	Difuso A_3A_1
1	0.9822	0.9695	0.9824	0.7790	0.9660	0.9659	0.9228
2	0.9833	0.8950	0.9831	0.9226	0.9092	0.7849	0.6838
3	0.9989	0.9658	0.9819	0.9134	0.9655	0.9656	0.8719

4	0.9989	0.9658	0.9819	0.9134	0.9059	0.7780	0.8719
5 & 6	0.9978	0.9529	0.9806	0.9004	0.9694	0.9665	0.9200
7 & 8	0.9839	0.9214	0.9794	0.8692	0.9032	0.7812	0.7912
9 & 10	0.9934	0.8782	0.9792	0.9176	0.9722	0.9669	0.9289
11 & 12	0.9853	0.9296	0.9805	0.9147	0.8979	0.7775	0.6827
13 & 14	0.9700	0.9639	0.9827	0.9029	0.9691	0.9658	0.9171
15 & 16	0.9789	0.9813	0.9848	0.9188	0.9044	0.7815	0.7913
17 & 18	0.9778	0.9898	0.9861	0.9060	0.9607	0.9646	0.8685
19 & 20	0.9656	0.9907	0.9860	0.8750	0.9161	0.7854	0.8719
21 & 22	0.9574	0.9817	0.9850	0.8726	0.9612	0.9650	0.9127
23 & 24	0.9475	0.9518	0.9837	0.7803	0.9130	0.7818	0.7939

B.2. Parámetros de las premisas de los modelos identificados.

En esta sección se encuentran los valores de los parámetros de las premisas de los modelos difusos de T&S identificados, empleando la notación presentada en la sección 2.2.2. Para el recurso eólico, los parámetros que definen las funciones de pertenencia de la Figura 3.9 se presentan en la Tabla A.4; para el recurso solar, los parámetros que definen las funciones de pertenencia de la Figura 3.13 se presentan en la Tabla A.5; mientras que para la demanda eléctrica, los parámetros que definen la Figura 3.27 se presentan en la Tabla A.6.

Tabla A.4: Parámetros de las premisas del modelo difuso de T&S del recurso eólico.

	$\bar{x}_{1,i} [m/s]$	$\sigma_{1,i} [m/s]$	$\bar{x}_{2,i} [m/s]$	$\sigma_{2,i} [m/s]$
MF_1^r	16.3606	15.3696	0.0000	12.0301
MF_2^r	16.5628	15.9758	0.0000	12.4684
MF_3^r	15.4529	14.4917	0.0000	11.9391
MF_4^r	14.7853	14.0180	0.0000	12.0625

Tabla A.5: Parámetros de las premisas del modelo difuso de T&S del recurso solar.

	$\bar{x}_{1,i} [kW/m^2]$	$\sigma_{1,i} [kW/m^2]$	$\bar{x}_{2,i} [kW/m^2]$	$\sigma_{2,i} [kW/m^2]$
MF_1^r	0.5930	0.3733	0.0000	0.0190
MF_2^r	0.6634	0.5043	0.0000	0.3115

MF_3^r	0.3984	0.7472	0.1106	68.7867
MF_4^r	0.0000	0.0218	0.5754	0.3974
MF_5^r	0.0000	0.0124	0.5641	0.3884
MF_6^r	0.0000	0.0074	0.5710	0.3937
MF_7^r	0.0000	0.1832	0.7563	0.5879
MF_8^r	0.0000	0.5482	1.0356	0.9560
MF_9^r	0.0000	1.1178	1.0363	1.6793
MF_{10}^r	0.6064	0.3833	0.0000	0.0310
MF_{11}^r	0.5961	0.3752	0.0000	0.0185

Tabla A.6: Parámetros de las premisas del modelo difuso de T&S de la demanda eléctrica

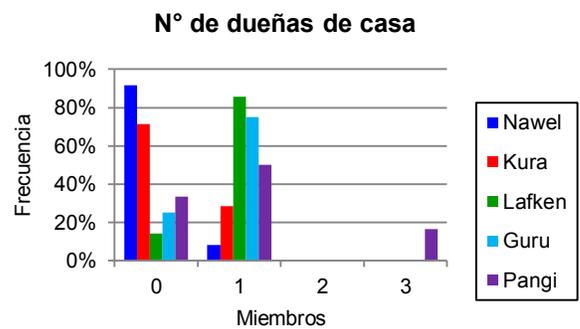
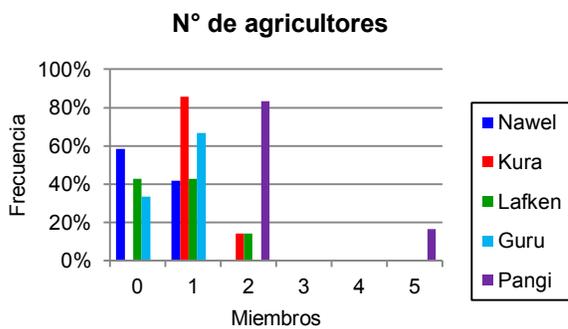
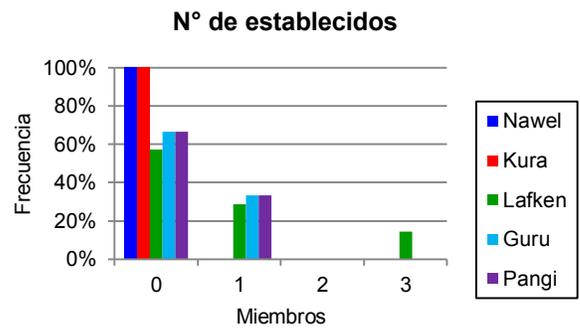
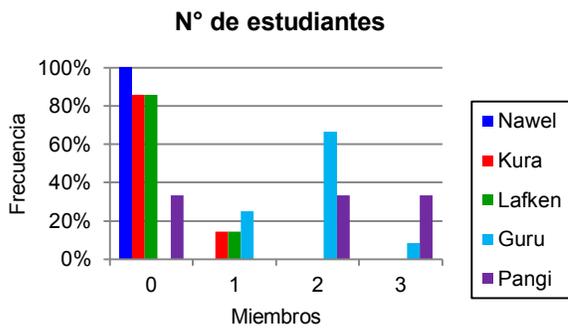
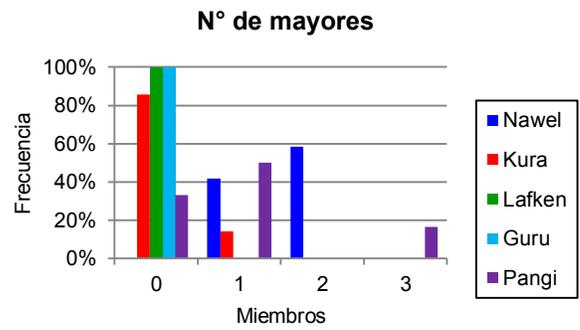
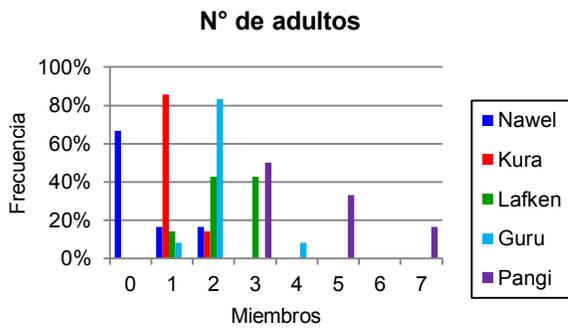
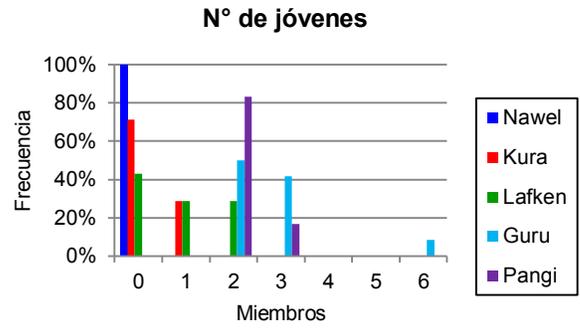
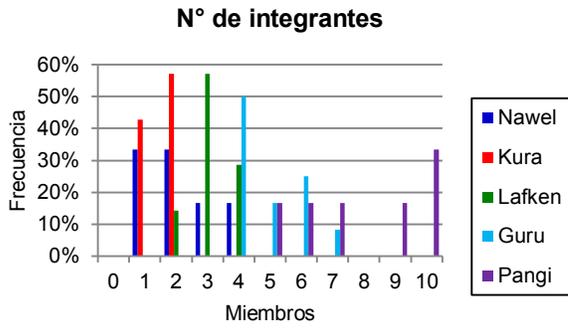
	$\bar{x}_{1,i} [kW]$	$\sigma_{1,i} [kW]$	$\bar{x}_{2,i} [kW]$	$\sigma_{2,i} [kW]$	$\bar{x}_{3,i} [kW]$	$\sigma_{3,i} [kW]$
MF_1^r	15.2259	2.9463	3.5016	3.4067	9.3184	2.3603
MF_2^r	4.5637	1.0690	3.5016	12.2567	11.6752	3.5066
MF_3^r	15.5591	2.7725	3.5016	3.9214	9.4726	2.2343

Anexo C. Resultados en simulación de demanda eléctrica.

El presente anexo se presenta información complementaria a las secciones 3.6.1. y 3.6.2. correspondiente a resultados adicionales obtenidos en el proceso de generación del perfil de demanda eléctrica de la comunidad.

C.1. Distribución de frecuencias por clase.

Esta sección presenta la distribución de frecuencias en cada una de las variables de una de las clases de hogares agrupados por el algoritmo SOM. Estos resultados juntos con los presentados a continuación en la sección C.1. permite identificar las principales características de clase.



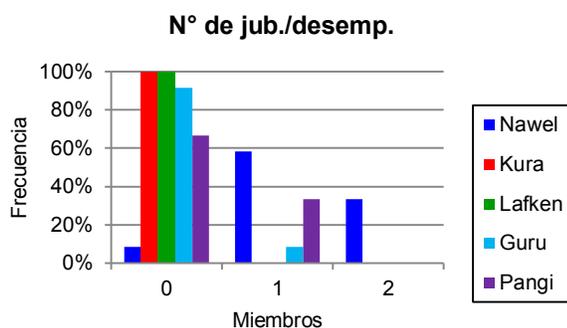


Figura A.1: Histogramas de variables por clase.

C.2. Índices estadísticos por clase.

En esta sección se presentan los valores medios, mínimos, máximos y desviación estándar de las variables de cada una de las clases de hogares agrupados por el algoritmo SOM. A través de estos resultados y los presentados en la sección C.1 es posible identificar las principales características presentadas en la sección 3.6.1.

Los valores de los índices estadísticos obtenidos se presentan en la Tabla A.7 para clase “Nawel”, en la Tabla A.8 para la clase “Kura”, en la Tabla A.9 para la clase “Lafken”, en la Tabla A.10 para la clase “Guru” y en la Tabla A.11 para la clase “Pangi”.

Tabla A.7: Índices estadísticos de la clase Nawel.

Variable	Media	Desv. Std.	Mínimo	Máximo
N° de integrantes	2.2	1.1	1.0	4.0
N° de jóvenes	0.0	0.0	0.0	0.0
N° de adultos	0.5	0.8	0.0	2.0
N° de mayores	1.6	0.5	1.0	2.0
N° de estudiantes	0.0	0.0	0.0	0.0
N° de establecidos	0.0	0.0	0.0	0.0
N° de agricultores	0.4	0.5	0.0	1.0
N° de dueñas de cada	0.1	0.3	0.0	1.0
N° de jub./desemp.	1.3	0.6	0.0	2.0

Tabla A.8: Índices estadísticos de la clase Kura.

Variable	Media	Desv. Std.	Mínimo	Máximo
Nº de integrantes	1.6	0.5	1.0	2.0
Nº de jóvenes	0.3	0.5	0.0	1.0
Nº de adultos	1.1	0.4	1.0	2.0
Nº de mayores	0.1	0.4	0.0	1.0
Nº de estudiantes	0.1	0.4	0.0	1.0
Nº de establecidos	0.0	0.0	0.0	0.0
Nº de agricultores	1.1	0.4	1.0	2.0
Nº de dueñas de cada	0.3	0.5	0.0	1.0
Nº de jub./desemp.	0.0	0.0	0.0	0.0

Tabla A.9: Índices estadísticos de la clase Lafken.

Variable	Media	Desv. Std.	Mínimo	Máximo
Nº de integrantes	3.1	0.7	2.0	4.0
Nº de jóvenes	0.9	0.9	0.0	2.0
Nº de adultos	2.3	0.8	1.0	3.0
Nº de mayores	0.0	0.0	0.0	0.0
Nº de estudiantes	0.1	0.4	0.0	1.0
Nº de establecidos	0.7	1.1	0.0	3.0
Nº de agricultores	0.7	0.8	0.0	2.0
Nº de dueñas de cada	0.9	0.4	0.0	1.0
Nº de jub./desemp.	0.0	0.0	0.0	0.0

Tabla A.10: Índices estadísticos de la clase Guru.

Variable	Media	Desv. Std.	Mínimo	Máximo
Nº de integrantes	4.9	1.1	4.0	7.0
Nº de jóvenes	2.8	1.1	2.0	6.0

Nº de adultos	2.1	0.7	1.0	4.0
Nº de mayores	0.0	0.0	0.0	0.0
Nº de estudiantes	1.8	0.6	1.0	3.0
Nº de establecidos	0.3	0.5	0.0	1.0
Nº de agricultores	0.7	0.5	0.0	1.0
Nº de dueñas de cada	0.8	0.5	0.0	1.0
Nº de jub./desemp.	0.1	0.5	0.0	1.0

Tabla A.11: Índices estadísticos de la clase Pangí.

Variable	Media	Desv. Std.	Mínimo	Máximo
Nº de integrantes	7.8	2.1	5.0	10.0
Nº de jóvenes	2.2	0.4	2.0	3.0
Nº de adultos	4.3	1.6	3.0	7.0
Nº de mayores	1.0	1.1	0.0	3.0
Nº de estudiantes	1.7	1.4	0.0	3.0
Nº de establecidos	0.3	0.5	0.0	1.0
Nº de agricultores	2.5	1.2	2.0	5.0
Nº de dueñas de cada	1.0	1.1	0.0	3.0
Nº de jub./desemp.	0.3	0.5	0.0	1.0

C.3. Parámetros de las cadenas de Markov.

A continuación, se presentan los parámetros que definen las cadenas de Markov identificadas, donde, para cada clase c y para cada grupo q de datos, se definen los centroides (valor de potencia de cada estado) μ_q^c , los vectores de probabilidades iniciales \mathcal{P}_{0q}^c y las MTE \mathcal{P}_q^c . Las cadenas de Markov identificadas para la clase “Nawel” se presentan en la expresión (A.2), para la clase “Kura” en la expresión (A.3), para la clase “Lafken” en (A.4), para la clase “Guru” en (A.5) y para la clase “Pangí” en (A.6).

$$\begin{aligned}
\mu_1^{nawel} &= [111 \quad 045 \quad 308]; \mu_2^{nawel} = 131; \\
P_{01}^{nawel} &= [0.44 \quad 0.44 \quad 0.13]; P_{02}^{nawel} = 1; \\
P_1^{nawel} &= \begin{bmatrix} 0.42 & 0.51 & 0.07 \\ 0.38 & 0.61 & 0.02 \\ 0.76 & 0.12 & 0.12 \end{bmatrix}; P_2^{nawel} = 1
\end{aligned} \tag{A.2}$$

$$\begin{aligned}
\mu_1^{kura} &= [602 \quad 900 \quad 150 \quad 221 \quad 301 \quad 106 \quad 410]; \\
\mu_2^{kura} &= [170 \quad 375 \quad 907]; \mu_3^{kura} = [149 \quad 102 \quad 294]; \\
P_{01}^{kura} &= [0.00 \quad 0.13 \quad 0.38 \quad 0.13 \quad 0.00 \quad 0.25 \quad 0.13]; \\
P_{02}^{kura} &= [0.71 \quad 0.29 \quad 0.00]; P_{03}^{kura} = [0.56 \quad 0.11 \quad 0.33]; \\
P_1^{kura} &= \begin{bmatrix} 0.11 & 0.09 & 0.30 & 0.13 & 0.06 & 0.26 & 0.06 \\ 0.05 & 0.15 & 0.25 & 0.20 & 0.10 & 0.15 & 0.10 \\ 0.10 & 0.06 & 0.28 & 0.12 & 0.16 & 0.24 & 0.05 \\ 0.05 & 0.02 & 0.25 & 0.22 & 0.13 & 0.29 & 0.04 \\ 0.16 & 0.02 & 0.21 & 0.19 & 0.12 & 0.23 & 0.07 \\ 0.11 & 0.02 & 0.26 & 0.07 & 0.16 & 0.31 & 0.07 \\ 0.15 & 0.04 & 0.26 & 0.04 & 0.04 & 0.37 & 0.11 \end{bmatrix}; \\
P_2^{kura} &= \begin{bmatrix} 0.78 & 0.18 & 0.04 \\ 0.67 & 0.27 & 0.07 \\ 0.84 & 0.11 & 0.05 \end{bmatrix}; P_3^{kura} = \begin{bmatrix} 0.53 & 0.40 & 0.07 \\ 0.25 & 0.71 & 0.04 \\ 0.59 & 0.18 & 0.23 \end{bmatrix}
\end{aligned} \tag{A.3}$$

$$\begin{aligned}
\mu_1^{lafken} &= [316 \quad 119]; \mu_2^{lafken} = [373 \quad 121 \quad 815]; \mu_3^{lafken} = [776 \quad 216]; \\
P_{01}^{lafken} &= [0.00 \quad 1.00]; P_{02}^{lafken} = [0.33 \quad 0.33 \quad 0.33]; P_{03}^{lafken} = [0.17 \quad 0.83]; \\
P_1^{lafken} &= \begin{bmatrix} 0.45 & 0.55 \\ 0.06 & 0.94 \end{bmatrix}; P_2^{lafken} = \begin{bmatrix} 0.35 & 0.55 & 0.11 \\ 0.24 & 0.72 & 0.04 \\ 0.28 & 0.50 & 0.22 \end{bmatrix}; P_3^{lafken} = \begin{bmatrix} 0.16 & 0.84 \\ 0.20 & 0.80 \end{bmatrix}
\end{aligned} \tag{A.4}$$

$$\begin{aligned}
\mu_1^{guru} &= [274 \ 032 \ 115]; \mu_2^{guru} = [096 \ 359 \ 787]; \\
\mu_1^{guru} &= [117 \ 453 \ 236 \ 837]; \\
P_{01}^{guru} &= [0.00 \ 0.86 \ 0.14]; P_{02}^{guru} = [0.64 \ 0.36 \ 0.00]; \\
P_{03}^{guru} &= [0.00 \ 0.67 \ 0.00 \ 0.33]; \\
P_1^{guru} &= \begin{bmatrix} 0.26 & 0.48 & 0.26 \\ 0.07 & 0.86 & 0.07 \\ 0.15 & 0.44 & 0.41 \end{bmatrix}; P_2^{guru} = \begin{bmatrix} 0.69 & 0.23 & 0.07 \\ 0.58 & 0.29 & 0.13 \\ 0.53 & 0.30 & 0.17 \end{bmatrix}; \\
P_3^{guru} &= \begin{bmatrix} 0.46 & 0.27 & 0.27 & 0.00 \\ 0.25 & 0.29 & 0.25 & 0.21 \\ 0.07 & 0.23 & 0.43 & 0.27 \\ 0.28 & 0.28 & 0.28 & 0.17 \end{bmatrix}
\end{aligned} \tag{A.5}$$

$$\begin{aligned}
\mu_1^{pangi} &= [079 \ 051 \ 241 \ 281 \ 166 \ 120 \ 021 \ 102]; \\
\mu_2^{pangi} &= [131 \ 107 \ 048 \ 080 \ 375 \ 172 \ 224 \ 290]; \\
P_{01}^{pangi} &= [0.17 \ 0.00 \ 0.08 \ 0.00 \ 0.08 \ 0.33 \ 0.00 \ 0.33]; \\
P_{02}^{pangi} &= [0.25 \ 0.08 \ 0.00 \ 0.08 \ 0.00 \ 0.17 \ 0.42 \ 0.00]; \\
P_1^{pangi} &= \begin{bmatrix} 0.14 & 0.12 & 0.06 & 0.16 & 0.06 & 0.14 & 0.14 & 0.20 \\ 0.15 & 0.11 & 0.00 & 0.00 & 0.15 & 0.21 & 0.09 & 0.30 \\ 0.32 & 0.05 & 0.09 & 0.18 & 0.18 & 0.05 & 0.09 & 0.05 \\ 0.02 & 0.07 & 0.09 & 0.40 & 0.09 & 0.16 & 0.18 & 0.00 \\ 0.13 & 0.16 & 0.10 & 0.10 & 0.10 & 0.26 & 0.03 & 0.13 \\ 0.16 & 0.16 & 0.07 & 0.03 & 0.01 & 0.22 & 0.14 & 0.21 \\ 0.11 & 0.07 & 0.04 & 0.15 & 0.07 & 0.15 & 0.13 & 0.29 \\ 0.10 & 0.13 & 0.02 & 0.02 & 0.05 & 0.17 & 0.16 & 0.34 \end{bmatrix}; \\
P_2^{pangi} &= \begin{bmatrix} 0.22 & 0.30 & 0.09 & 0.12 & 0.06 & 0.09 & 0.06 & 0.06 \\ 0.21 & 0.40 & 0.07 & 0.11 & 0.02 & 0.12 & 0.04 & 0.03 \\ 0.22 & 0.39 & 0.00 & 0.09 & 0.00 & 0.17 & 0.13 & 0.00 \\ 0.17 & 0.46 & 0.09 & 0.20 & 0.06 & 0.00 & 0.03 & 0.00 \\ 0.07 & 0.10 & 0.00 & 0.02 & 0.29 & 0.02 & 0.12 & 0.37 \\ 0.16 & 0.24 & 0.04 & 0.06 & 0.00 & 0.31 & 0.16 & 0.04 \\ 0.11 & 0.17 & 0.11 & 0.03 & 0.06 & 0.29 & 0.09 & 0.14 \\ 0.02 & 0.10 & 0.00 & 0.02 & 0.36 & 0.04 & 0.04 & 0.42 \end{bmatrix}
\end{aligned} \tag{A.6}$$

Anexo D. Dimensionamiento de sistema de riego.

La presente sección muestra los resultados parciales del procedimiento descrito en la sección 4.2.3. para la determinación de demanda eléctrica, derivado del sistema de riego propuesto para el desarrollo productivo de la comunidad en estudio.

D.1. Serie de suelo.

La Figura A.2 presenta el mapa de suelos de la zona norponiente de la IX Región de la Araucanía, donde es posible observar que la serie de suelo en la localidad en estudio, marcada con el indicador rojo, no ha sido identificada (“NR”: No Reconocida). Sin embargo, esta se encuentra aledaña a la zona cuyo suelo se identifica con la serie “NA”: Nahuelbuta, por lo que se asume que la localidad presenta condiciones de suelo similares.



Figura A.2: Series de suelo - Región de la Araucanía [131].

D.2. Requerimientos de riego.

A continuación, el detalle por mes de los cálculos realizados para el dimensionamiento del sistema de riego se presenta a continuación en la Tabla A.12 para el cultivo de papa de 1° temporada, en la Tabla A.13 para el cultivo de papa de 2° temporada, y en la Tabla A.14 para el cultivo de trigo y avena (que poseen las mismas características). De esta forma, el requerimiento de agua por riego y consecuentemente de energía, presentado en la Tabla 4.4, corresponde a la demanda integrada de los resultados obtenidos de las tres tablas mostradas a continuación.

Tabla A.12: Requerimientos de riego del cultivo de papa de primera temporada.

Variable	Unidad	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Precipitaciones	[mm/día]	0.42	0.24	0.77	1.42	3.04	4.03	3.15	3.73	1.60	1.21	0.80	0.22
ET_p	[mm/día]	4.00	3.60	2.90	2.10	1.50	1.20	1.20	1.40	1.90	2.70	3.40	3.90
k_c	[1]	-	-	-	-	-	0.45	0.70	0.80	1.10	1.10	1.00	0.70
ET	[mm/día]	-	-	-	-	-	0.54	0.84	1.12	2.09	2.97	3.40	2.73
Reserva día 1	[mm/día]	-	0.42	0.66	1.43	2.85	3.90	3.90	3.90	3.90	3.41	1.65	-
Humedad disponible	[mm/día]	0.42	0.66	1.43	2.85	5.89	7.94	7.05	7.64	5.50	4.62	2.45	0.22
ET_r	[mm/día]	-	-	-	-	-	0.54	0.84	1.12	2.09	2.97	2.45	0.22
Reserva día 30	[mm/día]	0.42	0.66	1.43	2.85	3.90	3.90	3.90	3.90	3.41	1.65	-	-
Déficit	[mm/día]	-	-	-	-	-	-	-	-	-	-	0.95	2.51
Excedente	[mm/día]	-	-	-	-	1.99	3.49	2.31	2.61	-	-	-	-
Consumo	[m ³ /Ha/día]	-	-	-	-	-	-	-	-	-	-	9.51	25.13
Riego	[m ³ /Ha/día]	-	-	-	-	-	-	-	-	-	-	10.56	27.93
Riego total	[m ³ /día]	-	-	-	-	-	-	-	-	-	-	15.69	41.47
Llenado de estanque	[hr/día]	-	-	-	-	-	-	-	-	-	-	0.21	0.55
Energía requerida	[kWh/día]	-	-	-	-	-	-	-	-	-	-	1.12	2.96

Tabla A.13: Requerimientos de riego del cultivo de papa de segunda temporada.

Variable	Unidad	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Precipitaciones	[mm/día]	0.42	0.24	0.77	1.42	3.04	4.03	3.15	3.73	1.60	1.21	0.80	0.22
ET_p	[mm/día]	4.00	3.60	2.90	2.10	1.50	1.20	1.20	1.40	1.90	2.70	3.40	3.90
k_c	[1]	1.10	1.00	0.70	-	-	-	-	-	0.45	0.70	0.80	1.10
ET	[mm/día]	4.40	3.60	2.03	-	-	-	-	-	0.86	1.89	2.72	4.29
Reserva día 1	[mm/día]	-	-	-	-	1.42	3.90	3.90	3.90	3.90	3.90	3.22	1.30
Humedad disponible	[mm/día]	0.42	0.24	0.77	1.42	4.47	7.94	7.05	7.64	5.50	5.11	4.02	1.52
ET_r	[mm/día]	0.42	0.24	0.77	-	-	-	-	-	0.86	1.89	2.72	1.52
Reserva día 30	[mm/día]	-	-	-	1.42	3.90	3.90	3.90	3.90	3.90	3.22	1.30	-
Déficit	[mm/día]	3.98	3.36	1.26	-	-	-	-	-	-	-	-	2.77
Excedente	[mm/día]	-	-	-	-	0.56	4.03	3.15	3.73	0.75	-	-	-
Consumo	[m ³ /Ha/día]	39.83	33.60	12.63	-	-	-	-	-	-	-	-	27.74
Riego	[m ³ /Ha/día]	44.26	37.33	14.04	-	-	-	-	-	-	-	-	30.82
Riego total	[m ³ /día]	65.73	55.44	20.85	-	-	-	-	-	-	-	-	45.77
Llenado de estanque	[hr/día]	0.87	0.73	0.28	-	-	-	-	-	-	-	-	0.61
Energía requerida	[kWh/día]	4.69	3.96	1.49	-	-	-	-	-	-	-	-	3.27

Tabla A.14: Requerimientos de riego del cultivo de trigo y avena.

Variable	Unidad	Ene	Feb	Mar	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic
Precipitaciones	[mm/día]	0.42	0.24	0.77	1.42	3.04	4.03	3.15	3.73	1.60	1.21	0.80	0.22
ET_p	[mm/día]	4.00	3.60	2.90	2.10	1.50	1.20	1.20	1.40	1.90	2.70	3.40	3.90
k_c	[1]	0.25	-	-	-	-	-	-	0.35	0.75	1.10	1.10	0.65
ET	[mm/día]	1.00	-	-	-	-	-	-	0.49	1.43	2.97	3.74	2.54
Reserva día 1	[mm/día]	-	-	0.24	1.01	2.43	3.90	3.90	3.90	3.90	3.90	2.14	-
Humedad disponible	[mm/día]	0.42	0.24	1.01	2.43	5.47	7.94	7.05	7.64	5.50	5.11	2.94	0.22
ET_r	[mm/día]	0.42	-	-	-	-	-	-	0.49	1.43	2.97	2.94	0.22
Reserva día 30	[mm/día]	-	0.24	1.01	2.43	3.90	3.90	3.90	3.90	3.90	2.14	-	-
Déficit	[mm/día]	0.58	-	-	-	-	-	-	-	-	-	0.80	2.32
Excedente	[mm/día]	-	-	-	-	1.57	4.03	3.15	3.24	0.18	-	-	-
Consumo	[m ³ /Ha/día]	5.83	-	-	-	-	-	-	-	-	-	8.01	23.18
Riego	[m ³ /Ha/día]	6.48	-	-	-	-	-	-	-	-	-	8.90	25.76
Riego total	[m ³ /día]	76.16	-	-	-	-	-	-	-	-	-	104.54	302.67
Llenado de estanque	[hr/día]	1.01	-	-	-	-	-	-	-	-	-	1.38	4.00
Energía requerida	[kWh/día]	5.44	-	-	-	-	-	-	-	-	-	7.47	21.62