



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

**MÉTODO PARA LA GENERACIÓN DE PERFILES DE DEMANDA EN
COMUNIDADES AISLADAS Y PREDICCIÓN DE DEMANDA DE CORTO
PLAZO, PARA MICRO-REDES BASADAS EN ENERGÍAS RENOVABLES**

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

JACQUELINE DEL ROSARIO LLANOS PROAÑO

**PROFESORA GUÍA:
DORIS SÁEZ HUEICHAPAN**

**PROFESOR CO-GUÍA:
RODRIGO PALMA BEHNKE**

**PROFESOR MIEMBRO DE LA COMISIÓN:
RUBÉN PEÑA GUÍÑEZ**

**SANTIAGO DE CHILE
ENERO 2012**

RESUMEN DE TESIS
PARA OPTAR AL TÍTULO DE
MAGÍSTER EN CIENCIAS MENCIÓN INGENIERÍA ELÉCTRICA
ALUMNA: JACQUELINE LLANOS
PROF. GUIA: DORIS SÁEZ
PROF. CO-GUIA: RODRIGO PALMA

“Método para la Generación de Perfiles de Demanda en Comunidades Aisladas y Predicción de Demanda de Corto Plazo, para Micro-redes Basadas en Energías Renovables”

El incremento del abastecimiento energético en comunidades aisladas empleando fuentes renovables, ha impulsado el estudio de la demanda eléctrica en estas zonas. Como etapa inicial de este tipo de proyectos se requieren perfiles de demanda eléctrica futuros que reflejen el comportamiento de los usuarios al disponer de energía ininterrumpida. Estos perfiles permiten además dimensionar las unidades de generación.

Una herramienta importante en micro-redes eléctricas basadas en energías renovables es el sistema de gestión de la energía (EMS) que proporciona consignas óptimas a las unidades de generación, basadas en: predictor de recursos de energía, y predictor de demanda eléctrica.

Esta tesis se enfoca en el desarrollo de un método que permita obtener perfiles de demanda diarios para comunidades aisladas que no cuentan con energía eléctrica, o que disponen de suministro eléctrico en horarios limitados. La propuesta es un método que incorpora un modelo que procesa entradas como: el número de habitantes, número de casas, número de escuelas, encuestas individuales por cada casa y número de luminarias del alumbrado público, obteniendo al final la demanda eléctrica total de la comunidad, y la demanda total considerando días festivos. Esta propuesta incorpora: módulo de entradas, módulo clasificador en base a mapas auto-organizados de Kohonen (SOM), módulo de búsqueda heurística, base de datos y módulos de generación de perfiles más específicos como por ejemplo de escuelas, y alumbrado público.

Además en este trabajo de tesis, para la predicción del consumo eléctrico a corto plazo, se usa redes neuronales artificiales, por su capacidad en el tratamiento de las no linealidades. Requiere como entrada la demanda de un día pasado obteniendo a su salida la predicción de la demanda eléctrica en un horizonte de dos días. Utiliza entrenamiento en línea, permitiendo que el modelo vaya cambiando los parámetros neuronales en función del incremento de mediciones de la demanda eléctrica disponible en línea, para el entrenamiento.

Para validar ambas propuestas se considera una micro-red ubicada en Huataconito, proyecto ESUSCON, que disponía de energía desde las 14:00 hasta 00:00. Se obtuvo un perfil diario de demanda de la comunidad, y se verificó que el perfil generado por el método en base a SOM se aproxima al perfil de demanda diario cuando se dispone de suministro ininterrumpido.

El modelo neuronal de predicción de la demanda eléctrica propuesto e implementado, utiliza mediciones reales, obteniendo errores MAPE del 13%, y superando a modelos lineales tradicionales. Este modelo de estimación actualmente es usado en el sistema de gestión de energía EMS en la micro-red de Huataconito.

Como trabajo futuro se plantea trabajar en predictores de demanda que consideren sistemas de gestión de demanda, utilizando señales indicadoras del comportamiento del uso de la energía por parte de los usuarios aplicada a la micro-red Huataconito.

Dedicado a Diego
A mi madre Isabel
A mis hermanos Henry, Tannya e Isabel
Sobrinos y abuelos

Agradecimiento:

Primero agradezco a Dios, por permitirme culminar esta etapa de mi vida. A mi compañero de sueños Dieguito O, por todo su amor, apoyo incondicional y comprensión. A mis padres, hermanos, por cada palabra de aliento y motivación, a mis sobrinos por permitirme ser parte de su vida a pesar de la distancia.

Mi agradecimiento a la Organización de Estados Americanos porque sin su auspicio, no hubiera sido posible realizar mis estudios de magister.

En particular, quiero manifestar mi gratitud a los profesores: Doris Sáez y Rodrigo Palma, por su tiempo, dedicación, y apoyo en la realización de este trabajo, sobre todo, por transmitirme sus conocimientos y su filosofía de trabajo.

Al grupo GEVI por su colaboración con el desarrollo de la tesis principalmente a: Lorenzo R, Nicolás L, Mariel, Natalia G. A mis compañeros de laboratorio: Fredy M, Carolina P, Diego M, Gabriel M, con quienes he compartido días de trabajo.

El culminar este trabajo trajo consigo experiencias engrandecedoras, entre ellas compartir con amigos que hicieron agradable mi estadía haciéndome sentir como en casa, mil gracias a: Javi K, Andresito R, Elenita S, Titi, Lucy B y sus familias, a Naty M, Jesy G, Diego A, Wilma P, Carolina P, Norelis, Maricela C, Efredy, Marcelo S, Gabriel H, Mavys, Rodrigo, Carlos T, Carlos B, Rossy y Carito.

A mis amigos que pese a la distancia se han mantenido presentes acompañándome durante este tiempo: JoséMaría R, Marcela P, Paola V, Katy S, Vicky R, Cristina G, Alex A, Andrés C, Renato H, Gerardo B, Darwin B, Carlos LL, Santiago F, Mauricio G, gracias por estar siempre pendientes de mi.

Índice General:

CAPÍTULO 1	1
INTRODUCCIÓN	1
1.1 Introducción	1
1.2 Objetivos.....	2
1.3 Alcance	3
1.4 Estructura de la tesis	3
CAPÍTULO 2	4
MICRO-REDES.....	4
2.1 Introducción	4
2.2 Definiciones, características y estructura de una micro-red	4
2.3 Unidades de generación y almacenamiento usadas en micro-redes	8
2.4 Gestión y control de micro-redes	9
2.5 Trabajos sobre la gestión de la energía (EMS) en micro-redes.....	12
2.5.1 EMS implementados en terreno	12
2.5.2 EMS implementados por simulación	15
2.5.3 EMS distribuido.....	17
2.5.4 EMS de una micro-red conectada a la red eléctrica	19
2.6 Discusión.....	21
CAPÍTULO 3	23
DEMANDA Y GESTIÓN DE LA DEMANDA ELÉCTRICA.....	23
3.1 Introducción	23
3.2 Demanda eléctrica.....	23
3.3 Consumo eléctrico	25
3.4 Tipos de demanda eléctrica.....	25
3.5 Demanda eléctrica residencial.....	26
3.6 Características de la demanda eléctrica	28
3.7 Demanda eléctrica en comunidades	31
3.7.1 Características del perfil de demanda en comunidades aisladas	32
3.7.2 Electrificación en comunidades aisladas.....	34
3.8 Gestión de la demanda eléctrica, Demand- Side Managment (DSM)	34
3.8.1 Beneficios del DSM y las oportunidades futuras	35
3.8.2 Técnicas de Gestión de la Demanda DSM.....	35
3.9 Discusión.....	40
CAPÍTULO 4	41
MODELOS DE PREDICCIÓN A CORTO PLAZO DE LA DEMANDA ELÉCTRICA	41
4.1 Introducción	41
4.2 Tipos de predicción de la demanda eléctrica	42
4.3 Clasificación de los métodos de predicción de la demanda eléctrica a corto plazo.....	43
4.4 Técnicas de predicción usadas para estimar la demanda eléctrica a corto plazo	46
4.4.1 Predicción de la demanda usando series de tiempo	46
4.4.2 Predicción de la demanda usando modelos de regresión	47
4.4.3 Predicción de la demanda usando modelos ARX.....	48

4.4.4 Predicción de la demanda usando modelos ARMA	50
4.4.5 Predicción de la demanda usando modelos ARIMA	51
4.4.6 Predicción de la demanda usando filtro de Kalman	51
4.4.7 Predicción de la demanda eléctrica usando razonamiento inductivo difuso (Fuzzy Inductive Reasoning FIR).....	52
4.4.8 Predicción de la demanda usando máquina de soporte vectorial para regresión (SVR Support Vector Regression)	54
4.4.9 Predicción de la demanda eléctrica usando redes neuronales artificiales (RNA).....	56
4.4.11 Predicción de la demanda eléctrica usando modelos híbridos.....	62
4.4.12 Predicción de la demanda eléctrica específicamente para micro-redes	67
4.5 Criterios de evaluación en modelos de predicción de demanda eléctrica	69
4.6 Discusión.....	70
CAPÍTULO 5	72
CONSTRUCCIÓN DEL PERFIL DE DEMANDA EN COMUNIDADES.....	72
5.1 Introducción	72
5.2 Método propuesto para la construcción del perfil de demanda en comunidades.	73
5.3 Estructura usada para el modelo de generación de perfiles de demanda	76
5.4 Módulos de la estructura del generador de perfiles de demanda eléctrica en comunidades	79
5.4.1 Módulo de entradas del modelo	79
5.4.2 Clasificación de usuarios.....	87
5.4.3 Búsqueda en la base de datos	92
5.4.4 Base de datos con distintos perfiles	94
5.4.5 Módulos de perfil residencial de casas encuestadas	95
5.4.6 Módulos de perfil residencial de casas no encuestadas	95
5.4.7 Módulos de perfil del alumbrado público.....	95
5.4.8 Módulos de generación del perfil de centros educativos.....	96
5.4.9 Módulos análisis del perfil actual.....	97
5.4.10 Módulos de factor de incremento de la demanda eléctrica en días festivos	98
5.5 Caso de Estudio (Comunidad Huatacondo)	98
5.6 Validación y análisis de resultados del modelo propuesto.....	115
5.7 Discusión.....	116
CAPÍTULO 6	118
PREDICCIÓN DE LA DEMANDA ELÉCTRICA EN MICRO-REDES.....	118
6.1 Introducción	118
6.2 Modelo predictor de la demanda eléctrica a corto plazo en micro-redes	119
6.3 Metodología usada para el diseño del modelo de predicción de demanda eléctrica en micro-redes....	120
6.4 Caso de estudio (Proyecto micro-red Huatacondo).....	125
6.4.1 Aplicación de la metodología para el diseño del modelo de predicción de demanda eléctrica bajo el escenario 8 días, al no disponer de mediciones históricas	125
6.4.2 Aplicación de la metodología para el diseño del modelo de predicción de demanda eléctrica bajo el escenario 4 meses.....	135
6.5 Modelo de predicción de demanda a corto plazo propuesto sin validar	156
6.6 Discusión.....	158
CAPÍTULO 7	160
CONCLUSIONES, APORTES Y LÍNEAS DE FUTUROS DESARROLLOS.....	160
7.1 Conclusiones.....	160
7.2 Aportes	162
7.3 Líneas de futuros desarrollos.....	162

ANEXO I.....	163
Predicción de la demanda eléctrica en el tiempo.	163
ANEXO II.....	167
Encuestas Aplicadas a Huatacondo	167
ANEXO III.....	180
Self-Organizing Maps (SOM)	180
ANEXO IV.....	189
Redes Neuronales Artificiales	189
REFERENCIAS.....	199

Índice de Figuras:

Figura 1 Estructura típica de una micro-red conectada a una subestación [7]	6
Figura 2 Flujo de información y funciones de PMS/EMS en tiempo real para micro-red [7]	10
Figura 3 Arquitectura de control supervisorio de micro-red [7]	11
Figura 4 Micro-red basada en energía renovable [19].	12
Figura 5 Diagrama de bloque del EMS aplicado a Huatacondo [19]	13
Figura 6 Red híbrida aplicada a una zona de Marruecos, usada para el estudio del control óptimo de una micro-red	14
Figura 7 Miro-red que incorpora energía solar y eólica que usa central de gestión de energía.	16
Figura 8 Funciones de control en el contexto de micro-redes, clasificadas por tiempo [22]	17
Figura 9 Sistema híbrido eléctrico propuesto en [23], con control descentralizado.	18
Figura 10 Estructura de control jerárquica [24]	19
Figura 11 Intercambio de información entre MCs y el MGCC	20
Figura 12 Perfil de demanda eléctrica del día 02 de Diciembre del 2010, construcción propia en base a mediciones de consumo de Huatacondo-Chile, por parte del grupo GEVI- Universidad de Chile.	24
Figura 13 Categorías energéticas tomado de la guía práctica de la buena energía de la Comisión Nacional de Energía – Chile.	26
Figura 14 Consumo energético en un ciclo de lavado tomado de la guía práctica de la buena energía de la Comisión Nacional de Energía – Chile [27].	27
Figura 15 Caracterización de la demanda, desarrollo en función de la información de [29]	29
Figura 16 Tipos de medidores instalados en las residencias.	30
Figura 17 Modelo conceptual de generación de perfil de carga virtual.	31
Figura 18 Comparación de la demanda eléctrica en zonas urbanas y comunidades aisladas.	32
Figura 19 Perfil de demanda eléctrica de la comunidad aislada Huatacondo [89]	33
Figura 20 Perfil diario de demanda eléctrica de una comunidad aislada Hutacondo con engría las 24 horas [89]	33
Figura 21 Perfil diario de demanda eléctrica de una zona urbana [90]	34
Figura 22 Nivelación de carga desarrollado con la información del módulo 14 de DMS, de sustentable energy regulation and policymaking for Africa [32]	37
Figura 23 Clasificación de los predictores de demanda antes del 2000 [58]	44
Figura 24 Métodos de estimación de la demanda eléctrica a corto plazo más recientes recogidos en la investigación [58]	45
Figura 25 Procedimiento del desarrollo de predictor de demanda usando modelos ARX	49
Figura 26 Aplicación del sistema de predicción de demanda usando modelos ARX	50
Figura 27 Razonamiento inductivo difuso [68]	52
Figura 28 Modelamiento de VSTLF, usando SVR, incluido en el paquete computacional WEKA	55
Figura 29 Aspectos a considerar para la selección de variables	55
Figura 30 Predicción de la demanda eléctrica a corto plazo usando como entrada el índice de calor calculado HI (Heat Index)	57
Figura 31 Estructura del modelo ANNSTLF para predicción de demanda usando como entradas predicciones de temperatura	58
Figura 32 Modelo de red neuronal implementado para predicción de demanda eléctrica [76].	60
Figura 33 Predicción de la demanda eléctrica usando redes tipo RBF [78]	61
Figura 34 Predicción de la demanda usando RBF con ajuste ANFIS [79]	62
Figura 35 Predicción de la demanda eléctrica usando transformada wavelet [80]	62
Figura 36 Estimación a corto plazo en base de días Similares, Wavelet y Redes Neuronales, (SIWNN-Similar Day-Based Wavelet Neural Network)	63
Figura 37 Entradas de las redes neuronales del modelo de predicción de corto plazo en base de días similares, wavelet y redes neuronales (SIWNN – Similar Day-Based Wavelet Neural Network) [82]	64
Figura 38 Predicción de la demanda eléctrica usando Wavelet y PSO en el entrenamiento de la red neuronal WNNs-PSO	65
Figura 39 Estructura de la estrategia SLTF de dos niveles	68

Figura 40 Estructura de la estrategia de predicción usando Redes neuronales mas algoritmos evolutivos EA.	69
Figura 41 Secuencia del método de generación de perfiles de demanda eléctrica	75
Figura 42 Estructura del modelo del generador predictor de eléctrica en una comunidad con días festivos	78
Figura 43 Estructura del modelo del generador predictor de eléctrica en una comunidad	79
Figura 44 Flujograma para adquirir las entradas del modelo	79
Figura 45 Disposición binaria de una red neuronal Kohonen.	88
Figura 46 Representación esquemática de un espacio de n-dimensiones de entrada en un espacio bidimensional mediante un mapa Auto-organizativo de Kohonen.	89
Figura 47 Arquitectura de SOM	89
Figura 48 Configuraciones más comunes en la retícula del SOM.	90
Figura 49 Esquema de búsqueda en la base de datos	92
Figura 50 Algoritmo de búsqueda de perfiles de clases en la base de datos	93
Figura 51 Perfiles de la base de datos del modelo generador de perfiles de demanda.	95
Figura 52 Encendido de las luminarias del alumbrado público	96
Figura 53 Perfil por unidad de un centro educativo	97
Figura 54 Ajuste de la demanda total de la comunidad generada	98
Figura 55 demanda eléctrica diaria actual de Huatacondo.	101
Figura 56 Número de personas que viven por casa	104
Figura 57 edades de los habitantes de Huatacondo	104
Figura 58 Actividades de los habitantes de Huatacondo.	105
Figura 59 Artefactos eléctricos de a localidad de Huatacondo (Proporcionada por ESUSCON *)	105
Figura 60 SOM de clasificación de tipos de hogares de Huatacondo.	108
Figura 61 Perfiles diarios que les caracteriza a las 7clases de familias encontradas en Huatacondo.	111
Figura 62 Demanda eléctrica residencial de Huatacondo	111
Figura 63 Perfil de demanda de casas no encuestadas de Huatacondo.	112
Figura 64 Perfil del alumbrado público de Huatacondo.	113
Figura 65 Perfil de centros educativos en Huatacondo	113
Figura 66 Demanda eléctrica total de Huatacondo	114
Figura 67 Demanda de Huatacondo generada ante días festivos	114
Figura 68 Demanda eléctrica real de Huatacondo versus demanda generada por el método propuesto.	116
Figura 69 Entradas del modelo propuesto	119
Figura 70 Metodología general para el diseño del modelo de predicción de demanda	121
Figura 71 Identificación Neuronal	122
Figura 72 Metodología para obtener el modelo de predicción de demanda eléctrica bajo el escenario uno.	126
Figura 73 Correlaciones entre variables escenario uno	127
Figura 74 Correlaciones de tiempos pasados con el dato a predecir	128
Figura 75 Predicción de la demanda eléctrica a 192 pasos en el primer entrenamiento del escenario 8 días	130
Figura 76 Predicción de la demanda eléctrica a 192 pasos al transcurrir 25 días de operación de la micro-red	130
Figura 77 Error MAPE a 192 pasos ante modificaciones de parámetros del modelo predictor (escenario 1)	131
Figura 78 Error MSE a 192 pasos ante modificaciones de parámetros del modelo predictor (escenario 1)	131
Figura 79 Varianza del error a 192 ante modificaciones de parámetros del modelo predictor (escenario 8 días)	132
Figuran 80 Errores absolutos de predicción a pasos.	133
Figura 81 Tiempos de entrenamiento al incrementar mediciones.	133
Figura 82 Predicción de la demanda eléctrica a un paso (escenario 1)	134
Figura 83 Predicción de la demanda eléctrica a 96 pasos (escenario 1)	134
Figura 84 Predicción de la demanda eléctrica a 192 pasos (escenario 1)	134

Figura 85 Metodología para identificar un modelo de predicción usado redes neuronales artificiales	135
Figura 86 Diagrama de dispersión entre la potencia solar y la demanda eléctrica	137
Figura 87 Diagrama de dispersión entre la velocidad del viento y la demanda eléctrica	138
Figura 88 Diagrama de dispersión entre la radiación solar y la demanda eléctrica	138
Figura 89 Diagrama de dispersión entre temperatura y la demanda eléctrica	139
Figura 90 Correlación entre variables	140
Figura 91 Histogramas de la correlación entre días similares de la semana de la demanda eléctrica	141
Figura 92 Regresores influyentes en la demanda eléctrica	142
Figura 93 Medición de la demanda eléctrica	144
Figura 94 Datos de validación del modelo de predicción	145
Figura 95 Error MAPE a 192 pasos (escenario 2)	145
Figura 96 Error MSE a 192 pasos (escenario 2)	146
Figura 97 Varianza del error a 192 (escenario 2)	146
Figura 98 Predicción de la demanda eléctrica a 192 pasos (escenario 2)	147
Figura 99 Predicción de la demanda eléctrica a 192 (escenario 2)	147
Figura 100 Error absoluto promedio de predicción por paso de predicción (escenario dos)	148
Figura 101 Predicción de la demanda eléctrica a un paso (escenario 2)	148
Figura 102 Predicción de la demanda eléctrica a 96 pasos (escenario 2)	149
Figura 103 Predicción de la demanda eléctrica a 192 pasos (escenario 2)	149
Figura 104 Predicción de la demanda eléctrica ante el primer entrenamiento en el escenario dos con entrenamiento en línea	150
Figura 105 Predicción de la demanda eléctrica con error de MAPE del 10.26% en el escenario	150
Figura 106 Predicción de la demanda eléctrica con altos errores de predicción en el escenario dos con entrenamiento e línea.	151
Figura 107 Error MAPE a 192 pasos promedio de 19 días en el escenario dos con entrenamiento en línea.	151
Figura 108 Error MSE a 192 pasos de 19 días el escenario dos con entrenamiento en línea	152
Figura 109 Varianza del error a 192 pasos en el escenario dos con entrenamiento en línea.	152
Figura 110 error absoluto a 192 paso promedio de 19 días frente al escenario dos con entrenamiento en línea	153
Figura 111 Tiempo de entrenamiento frente al escenario dos con entrenamiento en línea	153
Figura 112 Predicción de la demanda eléctrica a un paso	154
Figura 113 Predicción de la demanda eléctrica a 96 pasos	154
Figura 114 Predicción de la demanda a 192 pasos	154
Figura 115 Propuesta por valida del modelo predictor de demanda en micro-redes	157
Figura 116 Dispositivo de control d demanda	158

Lista de Definiciones de Símbolos

<i>Símbolo</i>	<i>Significado</i>	<i>Pag.</i>
D_{med}	Demanda Media	25
E	Energía	25
T	Periodo	25
$P(t)$	Potencia	25
f_c	Factor de Carga	26
D_{max}	Demanda Máxima	26
TD_{max}	Periodo de Demanda Máxima	26
t_{up}	Tiempo de utilización	26
f_{dem}	Factor de Demanda	26
P_{ins}	Potencia Instantánea	26
f_{div}	Factor de Diversidad	26
$tg(\varphi)$	Factor de Potencia	27
Q	Factor de Potencia	27
e	Error	71
ME	Error Medio	71
MAE	Error Medio Absoluto	71
RMSE	Error Medio Cuadrático	72
MAPE	Error Porcentual Absoluto Medio	73
$\vec{\omega}_i$	Vector de pesos de la neurona i	92
l_r	Razón dinámica del aprendizaje	92
h_{iv}	Función de vecindad	92
\vec{x}	Vector de Entradas al clasificador SOM	92
nn	Número de Neuronas	92
t	Iteración	92
l_{ro}	Razón de aprendizaje inicial	92
$d_{pública}$	Demanda total alumbrado público	97
n_l	Número de luminarias existentes	97
P_l	Potencia de consumo de las luminarias	97
$b_l(t)$	Variable Binaria de Encendido y apagado de luminarias	97
d_t	Demanda total de la comunidad	100
d_r	Demanda residencial de la comunidad	100
$d_{ce}(t)$	Demanda de Centros Educativos	100
d_f	Factor días festivos	100
i_p	Incremento de personas	100
H	Número de Habitantes	100
W	Pesos de la Red Neuronal	122

CAPÍTULO 1

INTRODUCCIÓN

1.1 Introducción

Actualmente muchas localidades aisladas cuentan con energía por horarios limitados, esto principalmente porque sus características geográficas impiden que se puedan conectar al sistema de transmisión, teniendo que ser abastecidos por horas y de forma autónoma con fuentes de energías costosas. Estos aspectos limitan la disponibilidad de un perfil de demanda eléctrica diario típico de comunidades, primero porque no hay abastecimiento continuo y segundo porque las necesidades energéticas de los usuarios se tienen que satisfacer de acuerdo a horarios establecidos.

Son justamente en estas comunidades aisladas, dotadas de recursos naturales y suministro limitado de energía, en donde proyectos de energización con fuentes renovables tienen aplicación, considerándose como una alternativa sistemas de micro-redes basados en energías renovables. Para la ejecución de este tipo de proyectos en su diseño se parte del dimensionamiento de las unidades de generación, para lo que se requiere conocer la demanda de la comunidad considerando que cuentan con energía ininterrumpida, perfil que por mediciones en las comunidades con limitaciones de energía es imposible obtenerlo, surgiendo la necesidad de un modelo que genere estos perfiles de demanda.

Algunos trabajos buscan la caracterización de la demanda usando principalmente una amplia base de datos, uno de ellos es el propuesto por Newborough [29] que caracteriza la demanda eléctrica del sector residencial en Reino Unido, utiliza un registro de datos de potencia, factor de potencia, temperatura dentro y fuera de hogares, muestreados por cuatro semanas en treinta casas de muestra, hay que considerar que las mediciones son con disposición de energía permanente caso opuesto al de comunidades aisladas, además de la disponibilidad de instrumentación que les permite tener mediciones en línea, bajo el mismo enfoque pero con menor instrumentación disponible se plante el trabajo realizado por Kim [32], donde realizan la construcción de un perfil de carga virtual, instalando medidores inteligentes o medidores de lectura automática Automatic Meter Reading (ARM) en determinadas casas de una zona, sin embargo no todas las casas, cuentan con esta instrumentación, a este grupo se las llama nARM, pero disponen de medidores tradicionales que registran consumos mensuales. Usando las mediciones de las casas ARM, y el consumo mensual de las nARM, realizan una clasificación de tipos de consumos mensuales tanto ARM

como nARM, y se establecen grupos. Luego de los datos ARM se identifica un perfil típico del grupo, y se genera el VLP total de la zona.

Estos trabajos son aplicados a demandas urbanas que cuentan con energía ininterrumpida, distinta a la demanda en comunidades aisladas, además en estos trabajos la caracterización de la demanda tiene como objetivo su uso en gestión de demanda.

Una vez que una micro-red inicia su operación, la predicción de demanda eléctrica, es usada como entrada de la unidad de gestión de la energía conocido como EMS (Energy Management System) [19]. Trabajos sobre modelos predictores de demanda eléctrica aplicados a micro-redes son escasos, estos tiene mayor complejidad principalmente porque a cambios mínimos de carga se ven reflejados en variaciones en la demanda total, mientras que en sistemas convencionales puede ser compensado con otros cambios en paralelo que no pueden ser percibidos. Amjady [86] proponen un modelo híbrido de dos niveles que usa redes neuronales y algoritmos evolutivos, para predecir demanda eléctrica a corto plazo para micro-redes.

Sin embargo el tema de predicción de demanda a corto plazo para sistemas eléctricos tradicionales es muy estudiado utilizando diferentes técnicas de predicción en su mayoría basados en el uso de redes neuronales artificiales con variantes en sus entradas [72][73][74]. Muchos modelos híbridos han considerado como base de predicción a la red neuronal y le han sumado etapas de pre-procesamiento como transformadas wavelets [80] [81][83].

Este trabajo de tesis abarca dos etapas. La primera que se enfoca en el desarrollo de un método que permita obtener perfiles de demanda diarios para comunidades aisladas que disponen de suministro eléctrico en horarios limitados. La segunda que corresponde al desarrollo de un estimador de la demanda eléctrica en corto plazo, para ser utilizado en sistemas de gestión de energía (EMS) de micro-redes, considerando pocos datos históricos de demandas pasadas. Ambas propuestas se validaran con datos reales de la micro-red en la comunidad de Huatacondo.

1.2 Objetivos

Objetivos Generales

- Desarrollar un modelo capaz de generar perfiles diarios de demanda eléctrica en comunidades aisladas, permitiendo el dimensionamiento de la cantidad de energía requerida para el diseño de proyectos de energización con micro-redes basadas en energías renovables.
- Predecir la demanda eléctrica a corto plazo para la gestión de energía en micro-redes, en operación isla.

Objetivos Específicos

- Desarrollar una herramienta de generación de perfiles diarios de demanda eléctrica lo suficientemente generalizada para que puedan ser replicados en distintos tipos de comunidades.
- Predecir la demanda eléctrica utilizando técnicas de inteligencia computacional contemplando las no linealidades propias de las series de tiempo.
- Incorporar aspectos sociales que intervienen en la demanda eléctrica tanto para los modelos de generación como de predicción.
- Implementar una herramienta computacional aplicada en el proyecto Huatacondo.

1.3 Alcance

Este trabajo de tesis incluye el desarrollo primero de un modelo generador de perfiles de demanda eléctrica para comunidades aisladas, como una herramienta computacional ejecutable, capaz de incluir las entradas y a su salida obtener dos perfiles diarios, uno perteneciente a la demanda de la comunidad, y el otro considerando días festivos.

Además se dispondrá de un modelo ejecutable predictor de demanda eléctrica capaz de incluir como entrada la demanda de un día pasado y a su salida obtener la predicción de la demanda para dos días. También se incluye un programa ejecutable encargado de realizar el entrenamiento en línea que a su vez le ingresa: datos de mediciones en línea, y se define cada cuanto se quiere realizar el entrenamiento, obteniendo a la salida los parámetros neuronales. Estos dos modelos tienen las características de poder ser incluidos dentro del sistema de gestión de energía EMS de la micro-red de la localidad de Huatacondo.

El modelo de predicción de demanda eléctrica no incorpora la gestión de la demanda. Pese a que se plantearon modelos para la predicción de demanda que incluyen como entradas registros de demanda de ciertas casas de la comunidad, no serán validos porque actualmente no se dispone de estas mediciones.

1.4 Estructura de la tesis

El contenido de este trabajo de tesis ordena los tres primeros capítulos para la etapa investigativa que incluye la revisión bibliografía del estado del arte, los dos siguientes son para describir las propuestas y su validación con un estudio de caso, mientras que el último capítulo incluye las conclusiones y trabajos futuros.

En el capítulo 2 se estudia a la micro-red, sus características, estructuras existentes, control y gestión de energía (EMS) en estos sistemas, además de las tecnologías más usadas en proyectos de este tipo.

El capítulo 3, estudia a la demanda eléctrica para establecer las diferencias entre la demanda en ciudades y comunidades aisladas, de utilidad para la caracterización de perfiles de demanda en comunidades. Además de analizar la gestión de la demanda eléctrica.

En el capítulo 4 se describe el estudio de las técnicas más usadas en la predicción de la demanda eléctrica a corto plazo.

Mientras que en el capítulo 5, se plantea un modelo propuesto de generación de perfiles de demanda eléctrica en comunidades aisladas, considerando la particularidad que únicamente se dispone de información de encuestas de la comunidad, y no se cuenta con mediciones históricas de la demanda eléctrica ininterrumpida de la localidad. Esta propuesta es validada en la comunidad de Huatacondo.

De igual forma en el capítulo 6, se plantea un modelo de predicción de la demanda eléctrica a corto plazo para micro-redes. Validado en el micro-red existente en Huatacondo, se analizan dos escenarios.

Finalmente en el capítulo 7 se sintetiza las conclusiones de este trabajo, su aporte y los trabajos futuros que surgieron.

CAPÍTULO 2

MICRO-REDES

2.1 Introducción

El objetivo del estudio de las micro-redes, previo al análisis de la demanda eléctrica y su predicción en este tipo de sistemas, es conocer las características, aspectos asociados a las micro-redes, proyectos para el control de micro-redes, y la importancia de la demanda eléctrica en este tipo de sistemas, además establecer las diferencias que tiene respecto a sistemas tradicionales cuando opera en modo isla con mayor interés en la demanda eléctrica.

Son varios trabajos los que analizan la demanda eléctrica y su predicciones sistemas grandes, y muy pocos los trabajos que enfocan su atención en demandas en pequeña escala características presentes en micro-redes. La demanda eléctrica es usada en el dimensionamiento de las unidades de generación, también en planificación, y en la operación del micro-red.

El sistema de gestión de la energía del inglés Energy Mangment System (EMS), es el que se encarga de prever la operación de la micro-red, en donde tiene importancia la predicción de la demanda eléctrica.

Este trabajo se enfoca en desarrollos aplicados a una micro-red, que incorporan energía renovables. La gestión de la micro-red en su planteamiento considera reducir costos de operación con la reducción de energías que involucran consumo de fósiles que son más costosos, y además el incremento del uso de energías renovables.

Este capítulo está estructurado primero por definiciones, características y la estructura de una micro-red, luego tecnologías usadas en generación distribuida. Después se analizan esquemas de control para micro-redes, y proyectos de gestión de la energía en micro-redes, y en función a esta información se hace un análisis en la discusión del capítulo.

2.2 Definiciones, características y estructura de una micro-red

El Consorcio de Soluciones de Tecnología para la Confiabilidad Eléctrica en inglés, Consortium for Electric Reliability Technology Solutions (CERT), definen a una micro-red, como un conjunto de cargas y micro-fuentes operando como un sistema único de energía y calor. Las micro-fuentes deben contar con electrónica de potencia para que proporcionen la flexibilidad necesaria para asegurar la operación. Este

control permite que la micro-red pueda presentarse como una unidad de control única que cumple con las necesidades locales de: fiabilidad y seguridad. Desde la perspectiva de la red, la ventaja central de un micro-red, es que puede ser considerado como una entidad controlada dentro del sistema de potencia. Los clientes se benefician de una micro-red en los siguientes aspectos: satisfacer sus necesidades locales de calor y electricidad con alimentación ininterrumpida, mejorar la fiabilidad, reducir las pérdidas de conexión, y regulación de tensión [1].

Palma [2], describe a una micro-red como una red eléctrica compuesta por: consumos, generadores distribuidos GD y sistemas de almacenamiento, que no requiere técnicamente de una conexión a la red. Sin embargo, usualmente opera conectada a la red con el fin de aprovechar una operación económica y segura a través de la venta y compra de energía [2].

La micro-red es una sección independiente de la red de distribución eléctrica que contiene capacidades de transmitir, producir y distribuir energía dentro de una área localizada. Los componentes principales de una micro-red son: recursos energéticos distribuidos del inglés Distributed Energy Resources (DER), cargas, controladores. Los tres deben coordinarse para obtener una operación eficaz. Además, el uso de una micro-red aumenta la fiabilidad y la calidad de la energía suministrada a las cargas [3].

La operación coordinada y el control de las fuentes de generación distribuida, junto con los dispositivos de almacenamiento tales como: capacitores de energía, baterías y cargas controlables, entre ellos los calentadores de agua y aparatos de aire acondicionado es central para el concepto de micro-redes [4].

Las micro-redes pueden crear cargas locales y aumentar la robustez del sistema de distribución, facilitar un mayor uso de energías renovables como la eólica y pequeños sistemas fotovoltaicos, aumentar la eficiencia energética y el nivel de confiabilidad para las cargas de los clientes [5].

Las micro-redes normalmente operan interconectadas a las redes principales de distribución, o también en isla, en caso de fallos externos. Desde el punto de vista del cliente, las micro-redes son similares a las redes tradicionales de distribución de baja tensión, pero no sólo satisfacen necesidades térmicas y de electricidad, además mejorarla confiabilidad local, mejoran la calidad de la energía mediante el apoyo a caídas de tensión y conducen a costos más bajos de suministro de energía [6].

Un esquemático de la estructura de una micro-red se muestra en la Figura 1, la micro-red se encuentra aguas abajo de la subestación de distribución, e incluye una variedad de unidades de recursos de energías distribuidas DER, además de diferentes tipos de usuarios finales de electricidad y/o calor.

Las DER incluyen unidades tanto de generación distribuida en inglés Distribution Generation (DG) y de almacenamiento distribuido en inglés Distributed Storage (DS) con diferentes capacidades y características.

La micro-red de la Figura 1, normalmente opera en un modo conectado a la red a través del transformador de la subestación. Sin embargo, también se espera que cuente con los controladores, estrategias operativas, y capacidad de energía suficiente, para suministrar al menos una parte de la carga, después de haber sido desconectado del sistema de distribución en el punto de acoplamiento común, en inglés conocido como Point of Common Coupling (PCC), y seguir funcionando de forma autónoma

aislado o modo isla. El PCC de la micro-red, constituye la conexión de la micro-red y el sistema, en el bus de baja tensión del transformador de la subestación [7].

La micro-red sirve para abastecer a una variedad de clientes, por ejemplo, edificios, viviendas, entidades comerciales, y parques industriales.

El departamento de energía de la unión de estados americanos en su programa DER para instituciones gubernamentales definen a los DER's como unidades pequeñas, modulares, descentralizadas, conectadas a la red o fuera de la red del sistema de energía, ubicadas en o cerca del lugar donde la energía se utiliza. Pudiendo ser implementadas en muchos tipos de instituciones como: grandes edificios de oficinas del gobierno, procesamiento de datos, comunicaciones y centros de control, hospitales, escuelas, y vivienda, parques nacionales, prisiones federales [8].

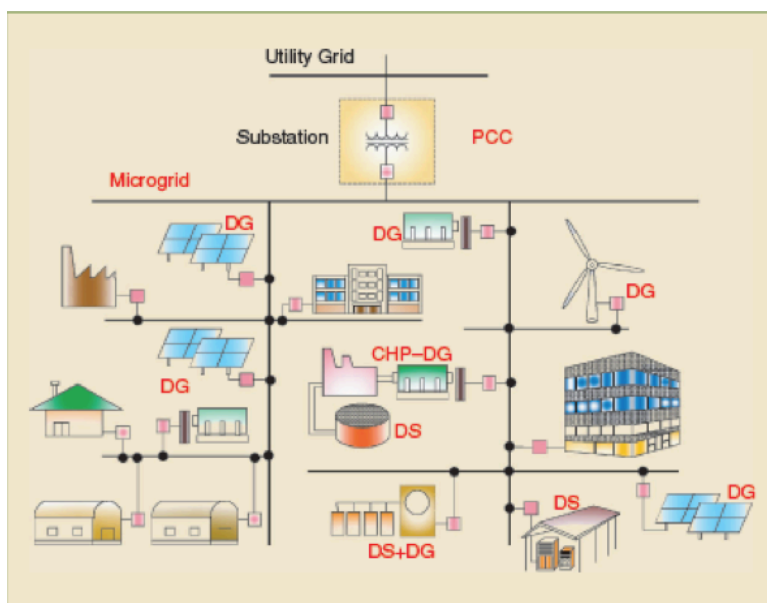


Figura 1 Estructura típica de una micro-red conectada a una subestación [7]

La estructura de la micro-red incluye: la interfaz, control y protección para cada micro-fuente así como el control de tensión de la micro-red, control de flujo de potencia, distribución de carga durante operación isla, la protección, la estabilidad, y sobre toda la operación.

La micro-red asume tres funciones críticas que son exclusivas de esta arquitectura:

Controlar las micro-fuentes.- El controlador de potencia y voltaje, junto con la micro-fuente proporcionan una respuesta rápida a las perturbaciones y los cambios de carga.

Administrador de energía.- Proporciona control de las operaciones mediante el envío de consignas (set points) para cada controlador de las unidades de generación distribuidas. El tiempo de respuesta de esta función se mide en minutos.

Protección.- La protección de una micro-red cuando las fuentes se interconectan con equipos de electrónica de potencia, requiere soluciones únicas para proporcionar la funcionalidad requerida.

La característica de cada controlador de las micro-fuentes es que responde en milisegundos y utiliza tensiones y corrientes medidas para controlar las micro-fuentes durante todo el sistema o eventos en la red. Una comunicación rápida entre micro-fuentes no es necesaria para el funcionamiento de la micro-red, cada inversor es capaz de responder a los cambios de carga de una manera predeterminada, sin datos de otras fuentes o lugares. Este arreglo permite micro-fuentes "plug and play", es decir las micro-fuentes se pueden agregar a la micro-red sin cambios en el control y la protección de las unidades que ya forman parte del sistema [7].

Siendo las unidades de generación distribuida elementos de la micro-red es necesario incorporar una breve conceptualización de generación distribuida propuesta por algunos trabajos.

Generación distribuida

Muchos documentos aseguran que no existe un consenso a nivel mundial, sobre una definición de generación distribuida, por los múltiples factores que afectan su definición como: tecnologías empleadas, límite de potencia, conexión a la red, etcétera.

Basado en información recopilada se generaliza la siguiente definición: La GD es una fuente de energía eléctrica, conectada directamente al sistema de distribución en baja tensión, o bien en instalaciones del usuario [11][12] [13], es decir en o cerca del consumo [9]. El propósito de generación distribuida es de proveer una fuente de potencia activa, de acuerdo con esta definición, la generación distribuida no necesariamente es capaz de proporcionar potencia reactiva [12]. Las unidades de generación distribuida pueden ser cualquier tecnología de generación a pequeña escala que proporciona electricidad en puntos cercanos al consumidor [10][11].

Los niveles de generación de un generador distribuido son muy discutidos y no se ha llegado a un nivel estandarizado. En la publicación de energías renovables no convencionales en el mercado eléctrico chileno de la Comisión Nacional de Energía, en el 2009, califican como pequeños medios de generación distribuida a medios de generación cuyos excedentes de potencia sean menores o iguales a 9000 kW, conectados a instalaciones de una empresa concesionaria de distribución, o a instalaciones de una empresa que posea líneas de distribución de energía eléctrica que utilicen bienes nacionales de uso público, en adelante pequeños medios de generación distribuidas o (PMGD). A los PMGD se les confiere el derecho de conectarse a redes de distribución [14]. El Departamento de Energía de los Estados Unidos (DOE EERE) Energy Efficiency and Renewable Energy, establece límites que van desde 1kW, hasta decenas de MW. [16].

Las definiciones anteriores de generación distribuida, no incluye una discusión de problemas de conexión a la red. Sin embargo, es muy importantes desde los aspectos técnicos, ya que hay diferencias significativas en el diseño de las redes de distribución y redes de transmisión destacándose tres aspectos importantes: en primer lugar, las redes de distribución son a menudo diseñadas para un propósito diferente al de las redes de transmisión. La principal diferencia es que los sistemas de distribución no están diseñados para la conexión de dispositivos de generación de energía, por ejemplo, la conexión de generación distribuida conduce a un cambio en la corriente de falla. Además el flujo de potencia en las redes de distribución por lo general es de una sola dirección y no bidireccional. En segundo lugar, las líneas de alta tensión, por ejemplo, líneas de transmisión o líneas urbanas de distribución, tienen una baja resistencia frente de líneas de baja tensión en redes de distribución. Y en tercer lugar, los extremos de baja

tensión de los sistemas de distribución no son por lo general conectados a sistemas de supervisión control y adquisición de datos, del inglés Supervisory Control And Data Acquisition (SCADA) por lo que la recopilación de datos necesarios para el control se torna difícil [13].

Los generadores distribuidos (GDs), fueron considerados para el operador de la red, como fuentes de perturbaciones. La principal desventaja de los GDs es que su competitividad frente a las unidades convencionales es baja y la integración al mercado de las mismas no es efectiva. Como consecuencia de esto nace la idea de agregar pequeñas unidades a una unidad de generación virtual, con el objetivo de lograr un tamaño suficiente, para poder integrarse al mercado eléctrico.

Bajo este criterio aparecen los generadores virtuales definido como un grupo de generadores distribuidos, operando bajo un esquema de coordinación común. Las ventajas son: Operación coordinada y la capacidad de integración de diversas fuentes tecnológicas.

Hay varios proyectos a nivel internacional que se enmarcan dentro de sistemas de generación virtual, como:

- Proyecto Fénix, financiado por la Unión Europea. Plantean a un generador virtual como una integración de: Comercial Virtual Power Plant (CVPP), Technical Virtual Power Plant (TVPP) y Análisis de Estabilidad para las Redes de Distribución con GD's [4].
- Proyecto VPP Dinamarca [17].
- Gobierno Alemán incentiva la investigación para la Integración de GD (MANNHEIM) [18].

2.3 Unidades de generación y almacenamiento usadas en micro-redes

Si bien es cierto una micro-red está constituida por varias unidades de generación distribuida no se define las tecnologías como un único tipo. Sin embargo, se plantea una clasificación de diferentes grupos de tecnología de la generación distribuida que pueden ser usadas en micro-redes como: generación distribuida renovable, generación distribuida modular y cogeneración o conocidos en inglés como Combined Heat and Power (CHP). En la Tabla 1 se detalla las tecnologías más usadas.

Tabla 1 Tecnologías de Generación Distribuida

	Tecnologías de Generación Distribuida
Generación Distribuida Modular	Ciclo combinadas Combustión interna Turbinas de combustión Micro- turbinas
Generación Distribuida Renovable	Pequeñas Hidráulicas Micro-hidráulicas Turbinas de viento Paneles fotovoltaicos Térmicos solar Biomasa Celdas de combustible Geotérmica Mareomotriz
Generación Distribuida Renovable CHP	Combinación de calor y electricidad

Tabla 2 Tecnologías de Almacenamiento Distribuido

	Tecnología de Almacenamiento Distribuido
Unidades de almacenamiento	Baterías Térmica. Bombeo. Volante de inercia.

2.4 Gestión y control de micro-redes

Una micro-red al incorporar varias unidades de generación distribuida, unidades de almacenamiento, distintos tipos de consumos a los cuales se les puede aplicar estrategias de control de demanda, requieren de un ente que gestione la operación de toda la micro-red para lograr una operación adecuada y óptima.

Yang, plantea que normalmente son tres tipos de control aplicados a micro-redes en operación isla: uno control centralizado, dos como control distribuido o tres control independiente o descentralizado [15].

La unidad que gestiona la micro-red es conocida normalmente como Energy Management System (EMS), es un sistema que prevé la operación de la micro-red, a través del envío de los consignas, de la cantidad de energía y tensión, a cada controlador de cada micro-fuente. Los valores reales de envío del P y V depende de las necesidades operativas de la micro-red. Algunos criterios pueden ser:

- Asegurarse que la demanda de calor y de energía sean abastecidas por las micro-fuentes.
- Asegurarse que la micro-red satisfaga contratos de operaciones con el proveedor de energía.
- Reducir al mínimo las emisiones y / o las pérdidas del sistema.
- Maximizar la eficiencia de las micro-fuentes, etcétera.

El Consorcio de Soluciones de Tecnología para la Confiabilidad Eléctrica, del inglés Consortium for Electric Reliability Technology Solutions (CERT) [1], manifiesta que para un funcionamiento de una micro-red, con más de dos DER's, requiere de una estrategia de gestión de potencia o llamado Power Management System (PMS) y una estrategia de gestión de energía (EMS).

Una respuesta rápida de PMS/EMS es más crítica en una micro-red que en un sistema convencional de potencia. Las razones son:

- Presencia de múltiples unidades pequeñas DER con diferentes capacidades de potencia y diferentes características.
- Falta de barra infinita cuando la micro-red opera en modo de isla. No existe una fuente de potencia dominante.
- Respuesta rápida del acoplamiento electrónico del DER, son unidades que pueden afectar en forma negativa la tensión / ángulo cuando las consignas provocan que la estabilidad falle.

La Figura 2, muestra el flujo de información y la operación del PMS/EMS en tiempo real, para una micro-red. El bloque PMS/EMS de gestión en tiempo real recibe los datos presentes y estimados de demanda y generación (dependiendo de los recursos disponibles), adicionalmente recibe información del mercado eléctrico, para enviar consignas adecuadas de control hacia: las fuentes despachables, cargas controlables, nivel de generación de cada unidad.

El PMS/EMS realiza tareas como: asignar los valores de P y Q a las unidades DER, comparte potencia activa y reactiva en forma proporcional entre los DER, respuesta ante perturbaciones y transientes, determinación de las consignas de potencia de las unidades DER para equilibrar la micro-red y restaurar la frecuencia, habilidad de re-sincronización de la micro-red con la red principal. En modo de conexión a la red, se debe minimizar las importaciones de energía de la red principal hacia la micro-red (recorte de punta).

En modo autónomo (isla) la salida de potencia debe cubrir la demanda total de la micro-red, de lo contrario las micro-redes deben ser sometidas a desprendimientos de carga, para que se conserve el equilibrio entre la generación y la demanda.

Por otra parte las estrategias de control de potencia están obligadas a minimizar el impacto de la dinámica en las micro-redes, por ejemplo los transitorios en modo de isla, las oscilaciones de frecuencia.

El PMS/EMS debe considerar, a corto plazo el equilibrio de la energía y a largo plazo la gestión de la energía. El equilibrio de potencia en el corto plazo incluye: regulación de tensión y de frecuencia, basados en el control de la repartición de potencia activa en las unidades y/o la desconexión de carga. También respuesta dinámica aceptable, para la restauración de la tensión y frecuencia luego de ocurrido un transitorio. Además cumplir con las restricciones de calidad de seguimiento de potencia para las cargas sensibles, y re-sincronización con el sistema principal de energía.

Mientras que la gestión de la energía a largo plazo incluye: Mantenimiento de un nivel adecuado de reservas, mientras se reajusta la programación de los puntos de operación de las unidades DER despachadas, basadas en un proceso de optimización y así controlar las importaciones /exportaciones desde la micro-red hacia la red principal, minimizar las pérdidas de potencia, maximizar la potencia de generación de las unidades basadas en tecnologías de energías renovables, minimizar los costos de producción de energía como por ejemplo de las unidades que emplean combustibles fósiles para generar. Para gestión también se debe contar con las especificaciones, limitaciones de cada DER, incluyendo el tipo de unidad, costo de generación, fuente de recurso primario, intervalos de mantenimiento, impacto ambiental. Manejo de la gestión de la demanda y la respuesta (Control de Perfil de Carga) y restauración de las cargas no sensibles que están desconectados y caída durante los transitorios, por ejemplo ante la desconexión de carga el requisito es que el sistema opere en modo de isla [7].

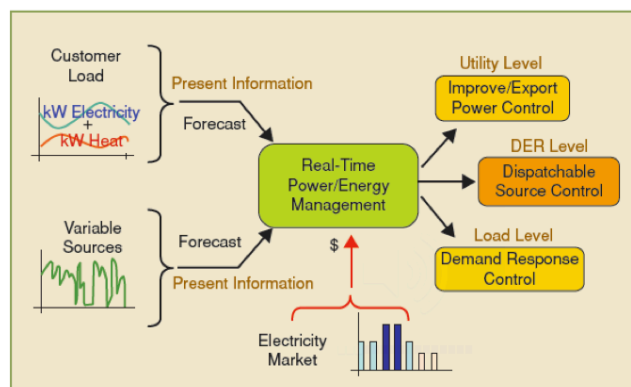


Figura 2 Flujo de información y funciones de PMS/EMS en tiempo real para micro-red [7]

En la Figura 3, se muestra el control supervisor de una micro-red cuando opera conectada a la red garantizando la totalidad o un sub-conjunto de estas funciones: suministro de energía eléctrica, participación en el mercado eléctrico, arranque en negro después de un colapso, prestación de servicios auxiliares, etc.

Para el control y la supervisión de la micro-red, se incluyen tres niveles jerárquicos como se muestra en la Figura 3, uno el operador de la red de distribución, del inglés Distribution Network Operator (DNO), con el Operador del Mercado (OM), en inglés Market Operator (MO), más abajo se encuentra el controlador central de la micro-red MCC, y finalmente los controladores locales en inglés Local Control (LC) asociados a cada uno de los DER's.

El DNO está destinado a una zona en donde existe más de una micro-red. Además uno o más operadores del mercado son responsables del buen funcionamiento del mercado de cada área específica.

Para el control de la micro-red en operación isla, se requiere del control central de la micro-red MCC y de la control local LC.

El MCC asume diferentes roles que van desde la maximización de operación de la micro-red hasta la coordinación de los LC. El LC controla las unidades DER y las cargas controlables dentro de una micro-red [7].




Figura 3 Arquitectura de control supervisorio de micro-red [7]

El control de la micro-red se puede realizar de forma centralizado o descentralizada.

En un sistema centralizado cada LC recibe consignas del MCC. El LC ejecuta la orden del MCC y tienen autonomía para: realizar la optimización local para el intercambio de potencia entre las unidades DER y seguimiento de carga rápido, cuando trabaja en modo autónomo.

Fundamentándose en una estrategia de oferta DER y un proceso de optimización de alto nivel, el MCC proporciona set points a cada unidad DER y decide.

En una operación descentralizada cada LC toma decisiones a nivel local. Las consignas de control las realizan los LC (por ejemplo optimización de la energía para el seguimiento de carga y maximización de la exportación de energía basada en los precios del mercado).

Un enfoque de control descentralizado pretende proporcionar la máxima autonomía a los DER y cargas dentro de una micro-red. La autonomía de los LC, implica que estos sean inteligentes y sean capaces de comunicarse entre sí. En el control descentralizado, la principal tarea de cada controlador no es

necesariamente maximizar el ingreso de la unidad correspondiente, sino contribuye a la mejora global del desempeño de la micro-red. Así la arquitectura debe ser capaz de incluir funciones económicas, los factores ambientales y requerimientos técnicos, por ejemplo arranque en negro.

Conceptualmente, los sistemas multi-agentes, en inglés multi-agent system (MAS) son una forma evolucionada del clásico sistema de control distribuido con la capacidad de controlar grandes y complejas entidades. Una de las principales características del MAS que distingue de las técnicas de control distribuido clásico, es que el software dentro de cada agente puede poseer inteligencia local. Cada agente emplea su inteligencia para determinar las acciones futuras y cómo influyen en el entorno de manera independiente [7].

2.5 Trabajos sobre la gestión de la energía (EMS) en micro-redes

Hay varios trabajos que se enfocan en el desarrollo de sistemas de gestión de energía, aplicados a micro-redes y redes híbridas que incorporan energías renovables como parte de sus unidades de generación.

2.5.1 EMS implementados en terreno

EMS implementado en la micro-red Huatacondo- Chile

Palma et al. [19], proponen un EMS para una micro-red que incluye unidades de generación renovables, con un mecanismo de gestión de demanda en inglés Demand Side Management (DSM) incorporado. La micro-red propuesta opera en modo isla, está constituida por unidades de generación, unidades de almacenamiento, cargas controlables, e interfaces físicas incorporadas en cada casa para la gestión de demanda (DSM). Las unidades de generación instaladas son: una planta fotovoltaica de 23,68 [kW], compuesta por 6 grupos de 14 paneles fotovoltaicos completando un área de 168 [m²]. Una turbina eólica de capacidad de 3kW, un grupo motor-generator diesel, de potencia nominal 120[kVA], 380[V]. Para el almacenamiento de energía cuentan con un banco de baterías compuesto por 96 baterías Trojan T-105 de 576[V] nominales, con capacidad de 205 A/h en 20 horas. Además del control de encendido y apagado de una bomba para el abastecimiento de agua potable. Para la gestión de demanda tienen instalados en cada casa indicadores del nivel de consumo eléctrico que disponen los usuarios, verde sinónimo de apto consumir energía, amarillo consumo moderado, y rojo que no es conveniente consumir. La descripción gráfica de este sistema se muestra en la Figura 4.

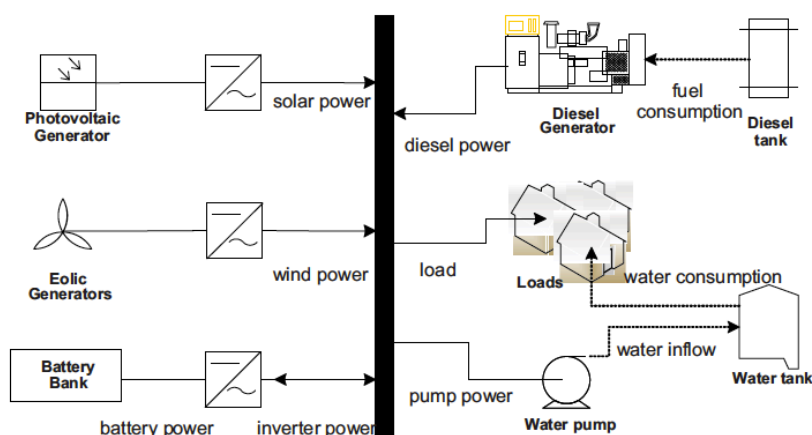


Figura 4 Micro-red basada en energía renovable [19].

El EMS propuesto se enfoca en los siguientes objetivos: Minimizar el uso de combustible diesel. Entregar consignas para cada fuente de generación incluido el banco de baterías. Enviar consignas de encendido y apagado de la bomba eléctrica de agua con el fin de mantener el tanque de agua lleno dentro de los límites predefinidos. Finalmente enviar señales a los consumidores promoviendo cambios de comportamiento.

En la Figura 5, se presenta el diagrama del EMS propuesto en este trabajo, en el que se distinguen como entradas: la predicción de la potencia fotovoltaica usando un modelo de predicción de radiación, predicción de potencia eólica, se incluye también como entrada el predictor de demanda eléctrica utilizando redes neuronales, y el predictor de consumo de agua potable que ocupa la misma técnica de predicción que la demanda eléctrica.

Las salidas que provee el EMS son: la referencia para la unidad diesel (P_d), la potencia de las baterías (P_b) la señal de encendido y apagado de la bomba de agua (B_p), y las señales de consumo (S_l) para la gestión de demanda.

La función objetivo busca minimizar costos e incluye en el primer término el costo del diesel, el segundo término el costo de encendido del generador diesel, y los dos últimos representan la penalización de la energía eléctrica y agua no aprovechada.

El problema se resuelve con programación entera mixta (MIP Mixed Integer Programming), resuelto por CPLEX.

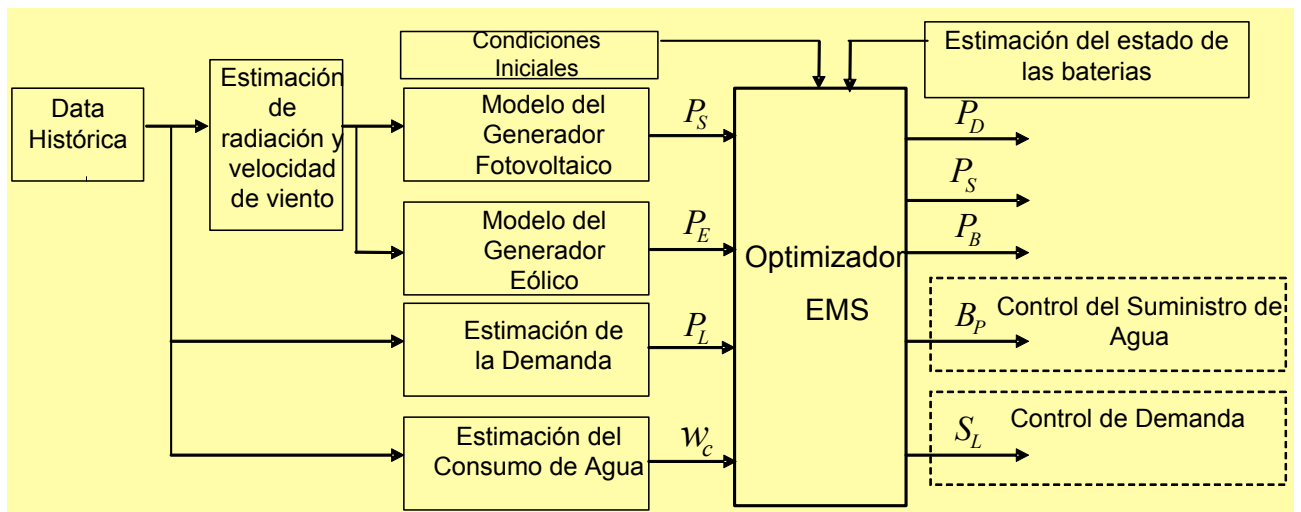


Figura 5 Diagrama de bloque del EMS aplicado a Huatacondo [19]

En este trabajo se presenta una estrategia de EMS para la óptima gestión de una micro-red, los resultados demuestran que el balance de energía en la micro-red se cumple para todos los casos de estudio, obteniendo beneficios económicos de un despacho coordinado en línea. Además de contribuir a la gestión eficiente del suministro de agua mediante la optimización de la activación de la bomba de agua como carga flexible.

EMS aplicado a una micro-red en Marruecos

Dagdougui et al. [20], proponen un problema de control óptimo en tiempo real para la gestión de una micro-red que contienen energías renovables. Utilizan un sistema integrado híbrido basado en una mezcla de generación de energía renovable, tecnologías convencionales y varias posibilidades para el

almacenamiento de la energía eléctrica como: plantas de bombeo, plantas hidroeléctricas reversibles, baterías, aire comprimido de almacenamiento, y almacenamiento de hidrógeno. Este modelo híbrido se caracteriza por integrar varios subsistemas. La razón para integrar hidrógeno y agua, como sistemas de almacenamiento radica en el aumento de la flexibilidad y la operatividad del sistema en general. El sistema se muestra en la Figura 6.

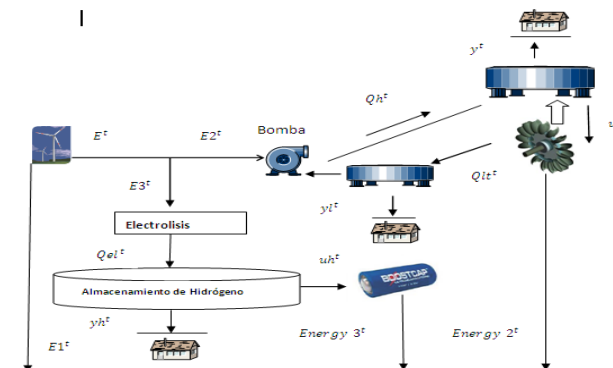


Figura 6 Red híbrida aplicada a una zona de Marruecos, usada para el estudio del control óptimo de una micro-red

Cuando un parque eólico se combina con las dos centrales hidroeléctricas, un sistema de bombeo, sistemas de almacenamiento de hidrógeno, se logran una serie de ventajas. Por ejemplo, durante las horas de bajo consumo, la energía eólica que no se utiliza para satisfacer la demanda (y si no se utiliza se descarta) se puede utilizar para producir hidrógeno, así como usar en la bomba de agua (con el fin de almacenar la energía potencial), que puede ser descargada cada vez que hay una necesidad de producir energía.

La energía almacenada tanto en el sistema de bombeo-hidráulica y en el tanque de hidrógeno puede ser re-utilizado para generar electricidad.

La energía eléctrica producida por el parque eólico se puede utilizar directamente para satisfacer la demanda. En el caso de los excedentes de energía, puede ser enviada a la estación de bombeo para elevar agua desde la parte inferior al depósito superior, y/o enviados a producir hidrógeno a través de un electrolizador.

El modelo incluye un problema de optimización para el control de las diferentes formas de almacenar energía. El objetivo es satisfacer por hora el hidrógeno, electricidad, y demanda de agua en un área de aplicación específica en Marruecos.

La respuesta dinámica cuyo objetivo es satisfacer las distintas demandas variables por hora, presenta una función objetivo que incluye los costos económicos relacionados con la operación de las celdas de combustibles y las plantas hidroeléctricas. Consta de cuatro términos, uno que penaliza niveles inferiores y superiores de agua e hidrógeno, otro que incluye la demanda de energía insatisfecha y exceso de generación, y dos términos relativos a variables de costos cuando la energía se produce a través de las turbinas hidroeléctricas o la celda de combustible.

Las restricciones que consideran en el problema de optimización son: capacidades de almacenamiento, capacidad de la planta, volumen máximo y mínimo de agua para los depósitos de almacenamiento, de igual forma del hidrógeno, flujo y caudal máximo y mínimo de las centrales hidroeléctricas, plantas de

bombeo, y electrolizador, variables binarias asociadas al control de las plantas hidroeléctricas, encendido y apagado de bombeo, pilas de combustible, etcétera. En general, el modelo de decisión es cuadrático con binarios y control de las variables continuas, y las variables continuas del estado. Utilizan Lingo 9.0 para su solución. Los autores han demostrado que el sistema híbrido permite satisfacer la energía por hora de los tres tipos de demanda, y las diferentes plantas se activan de acuerdo a la velocidad de fluctuación del viento disponible y la demanda de energía.

2.5.2 EMS implementados por simulación

EMS aplicado por simulación a una micro-red con energías renovables

Logenthiran y Srinivasan, [21] muestran una planificación a corto plazo de generación de una micro-red en modo isla. La micro-red que consideran en el estudio de caso, consiste en un sistema solar fotovoltaico en inglés Photovoltaics (PV), una planta eólica, 10 unidades térmicas y un banco de baterías. En este trabajo se describe un método de tres pasos para la planificación de la generación óptima de una micro-red en operación isla y en tiempo real. El primer paso del método consiste en obtener soluciones factibles iniciales que minimice el total de energía térmica, para el pre-despacho en inglés conocido como Unit Commitment (UC), el siguiente paso es resolver el problema de UC de la unidad térmica, minimizando los costos totales de producción que es la suma del costo de combustible y el costo de la puesta en marcha. El paso final es optimizar el despacho renovable-térmico en base a resultados del UC de las unidades térmicas, determinando la carga de cada unidad térmica. La metodología incorpora baterías en el UC térmico. La función objetivo que plantean incluye los costos asociadas a la producción de energía y puesta en marcha y parada de unidades. El problema resultante es un gran problema de optimización no lineal para el cual no hay ninguna técnica de solución exacta. El problema de optimización es no lineal entero mixto que consta de variables enteras para UC térmico y variables continuas para despacho económico de unidades renovables. El problema es descompuesto en optimización entera y optimización de variables continuas. Utilizan tres técnicas para la optimización: Relajación de Lagrange (LR), algoritmos genéticos (GA), y un algoritmo híbrido que combina relajación Lagrangiana y algoritmo genético (LRGA). Para la solución de optimización no lineal con variables continuas, usan programación dinámica (DP).

De los resultados de este trabajo se establece que la presencia de las energías renovables reduce el costo total de operación debido a que el costo de operación de las energías renovables es inferior. La presencia de banco de baterías para las fuentes renovables reduce el costo total de operación aun más. El sistema de baterías puede almacenar o suministrar energía desde o hacia las fuentes renovables siempre que sea posible o requiere. En este estudio, la batería almacena la energía cuando la potencia de renovables es mayor que la demanda, y proporcionar la energía de forma lineal cuando la energía renovable es menor que la demanda. Al comparar los tres tipos de algoritmos para lo solución óptima, mejores resultados son obtenidos al usar algoritmos genéticos.

Lu y Francois, [22] describe un sistema de gestión de energía de una micro-red. El sistema es presentado en la Figura 7, que integra dos generadores de energía renovable basada en viento y sol, y una turbina de micro-gas. El control central se encarga de gestionar a los tres grupos de generación: el primero constituido por una unidad de generación de micro gas, el segundo en cambio es un grupo formado por: paneles fotovoltaicos con un sistema de almacenamiento, que incluye un conjunto de baterías como dispositivo de almacenamiento a largo plazo y además un conjunto de súper-capacitores que se utilizan para la compensación rápida de potencia dinámica. El último grupo está formado por el generador eólico y

para el almacenamiento utilizan un proceso de electrolisis para producir hidrógeno, que luego es usado por las celdas de combustibles, además este grupo cuenta con súper-capacitores. El grupo basado en paneles fotovoltaicos y el eólico, cuentan cada uno de ellos con un gestor de energía local que realiza la operación de todo este grupo.

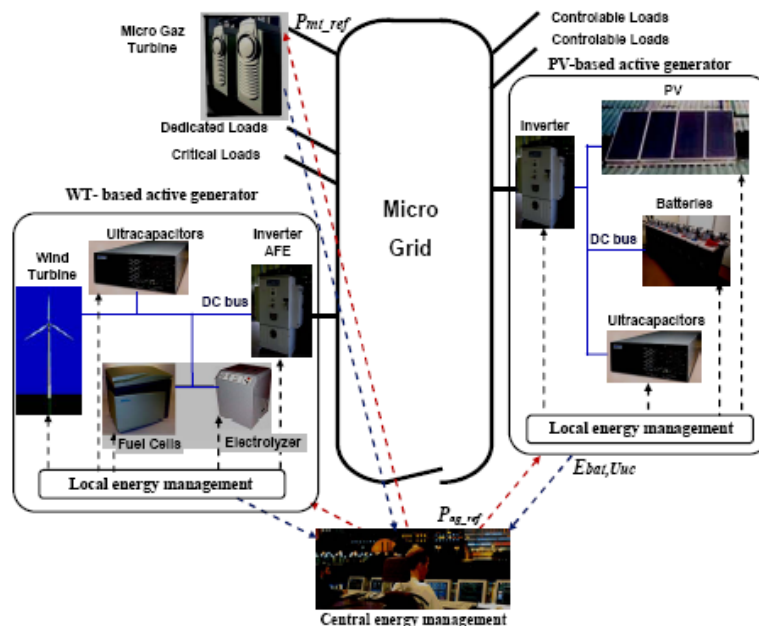


Figura 7 Micro-red que incorpora energía solar y eólica que usa central de gestión de energía.

La tarea del supervisor de la micro-red, es la gestión de la potencia y la energía entre las fuentes y cargas. La potencia activa y reactiva debe ser compartida entre las unidades DER. Así que el controlador de micro-red debe asignar las consignas de potencia y otras señales de control a las unidades DER, unidades de almacenamiento, y control de carga. La gestión de la micro-red deberá ser analizado a través de varias tareas que se han clasificado en una escala de tiempo Figura 8.

El control puede ser por día y horas, tiempo requerido para la administración de energía a largo plazo. En una escala de segundos y microsegundos, es aplicado en el balance de potencia en corto plazo.

La gestión de la energía a largo plazo a su vez consta de la planificación del despacho (día) y de un ajuste de producción (horas). El periodo de días es usado para la planificación del despacho, que de acuerdo con la información de la predicción de la demanda eléctrica, predicción de la generación y los precios en el mercado, el EMS decide la generación de cada unidad. En la planificación se realiza la programación diaria. El objetivo de la programación diaria es maximizar el uso de las energías renovables y asegurar la fuente de alimentación ininterrumpida. A más de la planificación se produce la gestión de las cargas no sensibles que pueden ser desconectadas, así como la provisión de un nivel adecuado de potencia de reserva acorde al mercado eléctrico, y la estimación de la demanda.

Después de la programación diaria, con el fin de seguir la demanda la gestión central de energía tiene que ajustar la producción de cada hora de acuerdo con el almacenamiento de energía disponible y la variación de predicción de la producción de recursos renovables (Figura 8). Los valores diarios de la planificación

de la energía de la micro turbina de gas y la generación renovable considerada son enviados a la unidad de ajuste de la producción.

La unidad de producción de ajuste corrige la potencia de referencia para las fuentes durante cada hora en la gestión de la energía central.

Por otro lado en escalas menores de tiempo segundos y micro segundos, el EMS se encarga del balance de potencia a corto plazo e incluye: "balance y despacho de potencia" entre las unidades de DER y unidades de almacenamiento de acuerdo al nivel de capacidad de almacenamiento y de los requisitos y limitaciones de cada unidad DER.

Además se enfoca en la regulación de voltaje RMS y control de frecuencia primaria.

El balance, el control de frecuencia es una solución convencional en operaciones sincrónicas de las plantas convencionales de energía. En una micro-red, también se puede utilizar métodos similares.

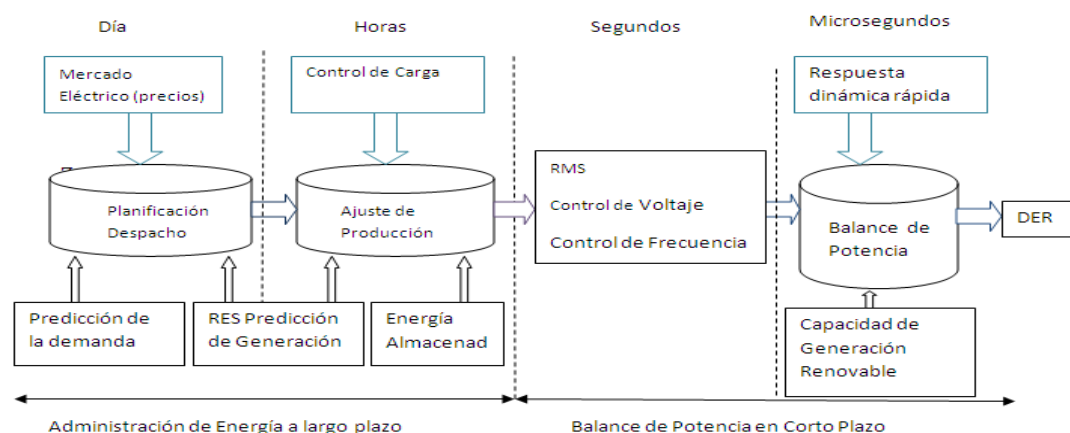


Figura 8 Funciones de control en el contexto de micro-redes, clasificadas por tiempo [22]

2.5.3 EMS distribuido

Lagorse y Simões [23], a diferencia de los trabajos anteriores proponen un EMS distribuido, para controlar el flujo de energía en un sistema de energía híbrido en inglés Híbrido Energy System (HES). El sistema híbrido que proponen se muestra en la Figura, consta de los siguientes elementos: Celdas fotovoltaicas (PV), dos baterías (BAT1 y BAT2), dos FC (FC1 y FC2), el bus de CC, un súper-capacitor (SC) y la carga. El SC está conectado directamente al bus de corriente continua, que acepta los cambios bruscos de carga, además presentan baterías para mantener una tensión constante en el bus de CC. Todos los elementos excepto el SC, están conectados a corriente continua a través de convertidores de corriente. Los controladores son denominados agentes, que determinan la cantidad de energía y la energía intercambiada por el elemento con el resto del sistema, cada unidad tiene un controlador por lo tanto es un agente.




Figura 9 Sistema híbrido eléctrico propuesto en [23], con control descentralizado.

El EMS es generalmente una unidad central que impulsa todos los elementos. Así, la complejidad en el diseño aumenta en el EMS con mayor número de unidades híbridas, por ejemplo, cuando un elemento se retira como consecuencia de avería o mantenimiento, el controlador no es capaz de adaptar su respuesta, La teoría del MAS tienen las siguientes características.

- Los agentes tienen un cierto nivel de autonomía, pueden tomar decisiones sin un centro de control.
- Los agentes son capaces de actuar en su entorno, perciben los cambios en el entorno y, responden a los cambios con sus propias acciones.
- Los agentes tienen capacidad social, lo que significa que los agentes pueden comunicarse entre sí.
- Los agentes tienen la representación parcial o no del medio ambiente.
- Asegurar el suministro de demanda, reducir al mínimo el costo operacional para maximizar la eficiencia global.

Bajo este criterio, el EMS es como una colección de entidades independientes que colaboran, a diferencia de los clásicos controladores, los controles descentralizados tienen capacidades adicionales que hacen los agentes. Ellos deciden por sí mismos el poder intercambiar con el bus de CC, lo que significa que la información no es proporcionada por un controlador central. Se pueden comunicar, lo que significa que pueden conocer la información procedente de otros agentes y también compartir información, por ejemplo, acerca de su capacidad, su estado actual, etcétera, esto se logra por un "Blackboard" que permite la comunicación, y el intercambio de información para llegar a una coordinación global. Escribir su mensaje en una pizarra que puede ser leído por todos los agentes. Este es fundamento de la tecnología MAS, ya que el objetivo es el control de un sistema muy complicado con datos mínimos para el intercambio de información y la mínima demanda de cómputo.

Los agentes que interactúan en este proceso de control son:

El "Agente Fuzzy", que es el control difuso en función de reglas para el control de carga descarga de las baterías. El algoritmo fuzzy se compone de 25 reglas las mismas que fueron creadas en función a la operación básica de las baterías como: cargar la batería cuando estado de carga y descarga en inglés State of charge (SOC) es baja y DC-bus SOC es alta. Descarga de la batería cuando su SOC es alta y del bus de CC- SOC es baja. Pero el control va más allá porque de existir excedentes estos deben ser enviados y distribuidos entre las demás baterías. Por lo que se requiere información como: la potencia máxima de las otras baterías, la disposición de carga, es decir si la batería está completamente cargada o está en falla,

además la corriente de descarga y la corriente de consumo de la carga. En base a esta información el agente puede deducir la cantidad de potencia que está autorizado a tomar.

Los “Agentes celdas de combustible” del inglés Fuel Cell (FC), son una fuente adicional para compensar la potencia que el sistema fotovoltaico no puede cumplir. La fuente tiene que ser empleada para reducir el consumo de hidrógeno y para aumentar la vida útil del FC. Este tiempo de vida útil se ve limitada tanto por el tiempo de funcionamiento y el número de inicio/parada de los ciclos.

La validación de esta técnica se obtuvo por un modelo de simulación, y han demostrado que la propuesta de EMS es capaz de adaptar su respuesta aún para cambios en configuraciones. Cuando el sistema se cambia, cada agente se adapta a su comportamiento, y el sistema continúa trabajando sin perturbación.

2.5.4 EMS de una micro-red conectada a la red eléctrica

Tsikalakis, y Nikos, [24] describen el funcionamiento de una micro-red y su gestión. La gestión del sistema tiene como objetivo optimizar el funcionamiento de la micro-red durante la operación interconectado, es decir, maximizar su valor mediante la optimización de la producción de generación distribuida y la capacidad de intercambiar energía con la red de distribución principal.

Los algoritmos de optimización desarrollados se aplican en un estudio típico de red de baja tensión que operan bajo varias políticas de mercados y partiendo de los precios reales del mercado al contado y las ofertas de los generadores distribuidos, reflejando costos realista de operación.

La jerarquía de control propuesta se muestra en la Figura, consta de tres niveles de control: El primero que son los controladores locales entre ellos los controladores de micro-fuentes (MC) y controladores de carga (LC). El segundo nivel son los sistemas de control central de micro-red (MGCC) y por último el sistema de gestión de la distribución, en inglés Distribution Management System. (DMS).




Figura 10 Estructura de control jerárquica [24]

El MC se aprovecha de la electrónica de potencia de las fuentes de generación distribuida. Utiliza la información local para el control de la tensión y frecuencia de la micro-red en condiciones transitorias. El MC sigue la demanda del controlador central, cuando está conectado a la red eléctrica, y lleva a cabo la optimización local de la producción de potencia activa y reactiva de la generación distribuida, además del rápido seguimiento de carga en modo de operación isla. Controladores locales instalados en las cargas controlables proporciona capacidades de control de carga siguiendo las órdenes de la MGCC para la gestión de la carga.

El MGCC optimiza la operación de acuerdo a: los precios de mercado de energía y gas, las ofertas recibidas por las fuentes de generación distribuida, las estimaciones de carga. Enviando señales a los MC,

con los niveles de su producción. Además, los consumidores de la micro-red podrían hacer una oferta para el suministro de las cargas durante la siguiente hora en los mismos intervalos minutos o podrían hacer una oferta para reducir sus cargas.

En este trabajo, el MGCC optimiza la operación en base a la generación distribuida y las ofertas de carga, y envía señales de despacho al MC y CL. La Figura 11 muestra el flujo de intercambio de información en operación de la micro-red típica en tales condiciones.

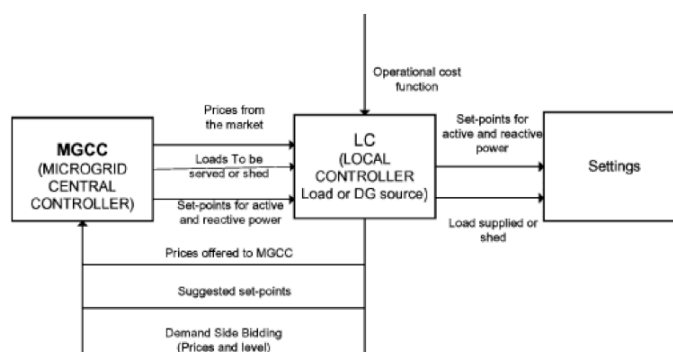


Figura 11 Intercambio de información entre MCs y el MGCC

El procedimiento de optimización depende de la política de mercado adoptada en la operación de la micro-red. Dos posibles políticas de mercado son usadas en este trabajo.

En la primera política, el MGCC tiene como objetivo servir a la demanda total de la micro-red, con su producción local, sin necesidad de exportar energía a la red de distribución aguas arriba. Para la operación de la red de distribución global, tal comportamiento es beneficioso, porque en el momento de demanda máxima, cuando el precio de la energía en el mercado son altos, la micro-red alivia posible congestión de la red total o parcialmente. Desde el punto de vista del consumidor, el MGCC minimiza el costo operacional de la micro-red, teniendo en cuenta los precios de mercado abierto, la demanda y las ofertas de generación distribuida. Los consumidores de la micro-red comparten los beneficios de la reducción de los costos de operación.

En la segunda política, la micro-red participa en el mercado abierto, comprando y vendiendo potencia activa y reactiva a la red, probablemente a través de un agregado o proveedor de servicios de energía similar. De acuerdo con esta política, el MGCC trata de maximizar el valor de la micro-red, es decir, maximizar los ingresos correspondientes, para intercambiar potencia con la red. Los consumidores pagan por su consumo de energía activa y reactiva en los precios de mercado abierto.

La micro-red se comporta como un solo generador capaz de aliviar la congestión de la red no sólo en la propia micro-red, sino también mediante la transferencia de energía a los alimentadores de la red de distribución.

Dos opciones se consideran para las ofertas de los consumidores. La primera que es los cambio de opciones. Donde los consumidores hacen dos ofertas diferentes para suministro de sus cargas de alta y de baja prioridad en el siguiente período de funcionamiento. Y la otra que es la opción de restricción donde

los consumidores ofrecen arrojar cargas de baja prioridad a precios fijos en el siguiente periodo de operación.

En ambas opciones, el MGCC informa a los consumidores sobre los precios de mercado abierto, acepta las ofertas de los consumidores cada minuto m en m intervalos de una hora, ejecuta las rutinas de optimización y envía señales a las LCs de acuerdo con él o los resultados optimización.

Los precios de mercado abierto sólo ayudan a los consumidores a realizar sus ofertas.

El MGCC optimiza el funcionamiento de la micro-red de acuerdo a las ofertas de los generadores distribuidos y las cargas.

En la opción de cambio, el MGCC resume las ofertas de los generadores distribuidos en orden ascendente y las ofertas de la demanda en orden descendente. Para decidir qué fuentes de generación distribuida funcionan durante la siguiente hora y cuales cargas serán abastecidas. El funcionamiento óptimo se logra en el punto de intersección de las ofertas de los productores y los consumidores.

2.6 Discusión

Este trabajo se enmarca en el desarrollo de modelos aplicados a micro-redes de ahí la importancia de conocer su definición y generalidades asociadas a las mismas, extrayendo ideas de distintos autores se podría definir de forma generalizada a una micro-red como una red eléctrica que puede transmitir, producir y distribuir energía dentro de una área determinada. Formada por unidades de generación distribuida, unidades de almacenamiento y cargas. Para la coordinación y operación de una micro-red se requiere de una unidad de gestión de la energía (EMS), que envíe consignas de la cantidad de energía requerida a las unidades de generación para satisfacer demandas.

En este capítulo se aborda de forma general al generador distribuido, porque tiene incidencia en la micro-red, por ser uno de sus elementos, pero no se cuenta con una definición estandarizada, sin embargo la mayoría de conceptualizaciones plantea que un generador distribuido es una unidad de generación eléctrica de cualquier tipo de tecnología, conectadas directamente a la red de distribución, a la carga o cercana a ella.

El sistema de gestión de la energía (EMS), es un aspecto importante en la operación óptima de una micro-red, que a diferencia de los sistemas tradicionales presenta varias unidades pequeñas con diferentes capacidades, y no cuenta con barra infinita en modo isla. Como descripción general, el EMS preverá la operación de la micro-red, con el envío de consignas de la cantidad de energía asignada a cada unidad, consignas para control de encendido y apagado de cargas. Un EMS busca minimizar las pérdidas de potencia, maximizar el uso de potencia de las unidades basadas en energías renovables, reducir al mínimo el uso de energías en base a combustible fósil para generar, restauración de carga no sensibles desconectadas.

En trabajos donde plantean EMS para micro-redes, las estructuras de la micro-red incorporan al menos una unidad de generación renovable en su mayoría eólica [19] [20] [22], plantas fotovoltaicas [19] [20] [21] [22] [23], hidráulicas [20]. Por otra parte como unidades de generación que usan algún fósil se tiene: unidades de generación que utilizan diesel [19] [21]. Unidades de generación a gas [22]. Además se presentan celdas de combustible [23] [20] [22]. Como unidades de almacenamiento baterías [19] [20] [21]

[22] [23], bombeo [20], hidrógeno [20] [22], y súper-capacitores [22] [23]. De los trabajos con respecto a las propuestas de EMS, se puede destacar que en el trabajo propuesto por Palma et al. Incorpora en la gestión de la micro-red señales para la gestión de la demanda, mediante una conducta adecuada de los usuarios de la energía, además del control adecuado del encendido y apagado de una bomba [19]. Daugdgui aparte de abastecer la demanda eléctrica busca satisfacer la demanda de agua potable, y la demanda de hidrógeno para procesos locales [20]. Lougenthiran, resalta la necesidad de optimizar costos ya que su mayor cantidad de generación se basa en generación térmica [21]. Lu [22] utiliza un EMS central, pero a su vez cuenta con gestores locales por grupos y son estos sub gestores de energía son los que controlan el almacenamiento de la energía, un grupo por ejemplo podrían estar integrados por: eólica, celda de combustible, batería, electrolisis, ultra-capacitores. Mientras que Tsikalakis analiza una micro-red, conectada al sistema, buscando maximizar la operación de la micro-red mediante la optimización de la producción de la generación distribuida y la capacidad de intercambio de energía con la red de distribución principal, al igual que Lu [22], consideran en su planteamiento los precios del mercado. Lagorse a diferencia de todas las propuesta analizadas usa un control distribuido [23].

Para la solución del problema de optimización las herramientas más usadas son: CPLEX [19], Leng 9 [20], algoritmos genéticos [21] y Lagrange [21].

Un elemento importante de las micro-redes es la demanda eléctrica, que tiene un comportamiento distinto a la demanda aplicada a los sistemas eléctricos convencionales, en el siguiente capítulo, se estudia la demanda, y posteriormente la predicción de la misma. La predicción de la demanda tiene una gran importancia en la gestión de la energía EMS, por ser una de las entradas de esta unidad.

CAPÍTULO 3

DEMANDA Y GESTIÓN DE LA DEMANDA ELÉCTRICA

3.1 Introducción

La demanda eléctrica es uno de los elementos más importante dentro de un sistema eléctrico, dependiendo de la demanda máxima y su proyección en el tiempo se puede realizar el dimensionamiento de la generación requerida en una micro-red. El crecimiento de la demanda eléctrica conlleva a realizar estudios de análisis para determinar las características y los factores relevantes de su incremento. En el sistema eléctrico se distinguen típicamente tres tipos de consumidores: los industriales, los comerciales, y los residenciales siendo este último grupo el de mayor importancia para este estudio por tratarse del análisis específicamente de una micro-red aislada.

En este capítulo se busca obtener la información teórica que luego permita realizar la caracterización de perfiles de demanda en comunidades, interpretar la influencia de distintos electrodomésticos en los perfiles, determinar herramientas que faciliten el caracterizar la demanda eléctrica, y posteriormente sean de utilidad para incorporarse en sistemas de gestión de la demanda, con la realimentación de información de proyectos realizados internacionalmente.

La estructura de este capítulo parte con la conceptualización general de la demanda eléctrica, sus características más relevantes y su diferencia con el consumo eléctrico, además los distintos tipos de consumidores, haciendo un énfasis importante en la demanda residencial, sus características, factores que influyen en su modificación, y el análisis de los electrodomésticos más incidentes en los hogares, que dependiendo de la forma de uso definen el perfil en los hogares, y finalmente gestión de la demanda, sus aspectos importantes, características, beneficios, técnicas para la implementación y requerimientos de implementación.

3.2 Demanda eléctrica

La demanda eléctrica es la potencia presente en los terminales de un sistema promediada en un intervalo corto y específico de tiempo por ejemplo 25, 30 minutos o 1 hora. Se define como la cantidad, de energía que pueden ser adquiridos en los diferentes precios del mercado por un consumidor o por el conjunto de

consumidores en un momento determinado [25]. La demanda eléctrica varía diariamente y estacionalmente, y dado que la demanda es en gran medida incontrolable ante interrupciones puede resultar muy costosa, la capacidad instalada de generación debe ser capaz de cumplir con la máxima demanda diaria presente. Además, es necesario que exista suficiente capacidad de energía disponible para hacer frente a la incertidumbre en la disponibilidad de generación y el aumento imprevisto de la demanda [26].

Características de la demanda eléctrica

La demanda eléctrica presenta variaciones durante todo el tiempo que son dependientes del día o del tipo de cliente. Los perfiles pueden ser variantes dependiendo si son días laborables, fines de semana, festivos, además de la temperatura, es decir estaciones climáticas, además influyen los espectáculos que cada vez son más comunes, el régimen educativo también es incidente porque define temporadas de vacaciones, e incluso el aspecto económico es determinante en los perfiles de demanda. Hay otros factores que inciden en la curva de la demanda de energía eléctrica en general como por ejemplo; el constante desarrollo económico, alto nivel de electrificación, uso ineficiente de la energía, empleo de equipos obsoletos, malos hábitos en el uso de la energía eléctrica, tarifas sin señal de costo.

En el perfil de la demanda se puede distinguir: la demanda máxima, también conocida como demanda punta, es el máximo valor de demanda en un período determinado. La demanda mínima, también conocida como carga base, es el mínimo valor de demanda en un periodo determinado. Finalmente la demanda media, que es la relación entre la energía consumida durante un periodo considerado y la duración de dicho período.

$$D_{med} = \frac{E}{T} = \frac{\int_0^T P(t)dt}{T} [W] \text{ Ec. 1}$$

Perfil de Demanda.- También conocido como curvas de carga. Estas pueden ser: diaria, semanal, anual, dependiendo del período que se esté considerado.

En la Figura 12, se muestra un perfil de demanda, el eje vertical corresponden a la demanda y el eje horizontal a la hora del día. El área bajo la curva, en color amarillo es el consumo.

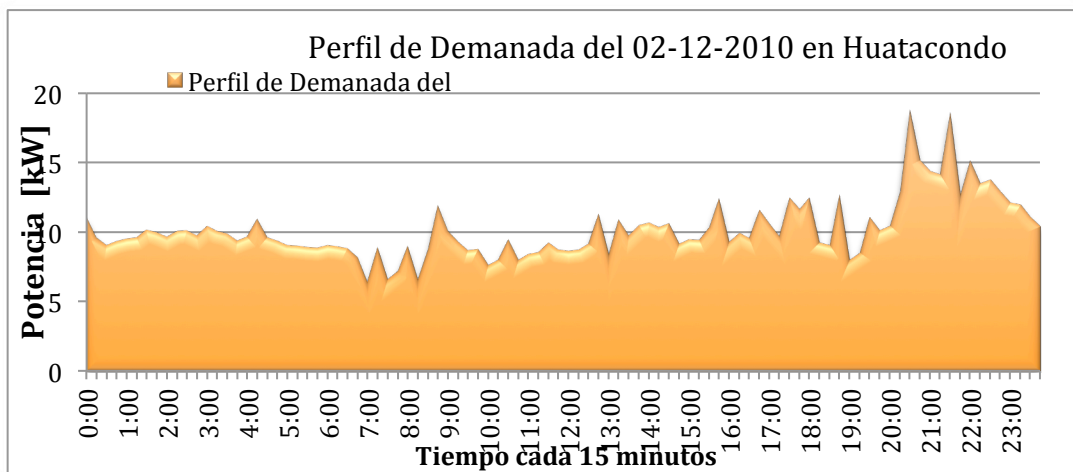


Figura 12 Perfil de demanda eléctrica del día 02 de Diciembre del 2010, construcción propia en base a mediciones de consumo de Huatacondo-Chile, por parte del grupo GEVI- Universidad de Chile.

Factor de Carga.- Es el cociente entre la demanda media y la demanda máxima, medido en un intervalo de tiempo específico, descrito en la ecuación:

$$f_c = \frac{D_{med}}{D_{max}} = \frac{E}{TD_{max}} = \frac{\int_0^T P(t)dt}{T D_{max}} \text{ Ec. 2}$$

El factor de carga varía entre el 12% para consumos domiciliarios, y 100% bombeo de agua. En Europa este factor es conocido como tiempo de utilización de la punta o cociente entre energía consumida en el período y la demanda máxima.

$$t_{up} = \frac{E}{D_{max}} = T * f_c \text{ Ec. 3}$$

Factor de demanda.- Mide la utilización real que se hace del equipo instalado. Es la relación entre demanda máxima de uno o varios consumidores durante un período específico y la potencia eléctrica instalada:

$$f_{dem} = \frac{D_{max}}{P_{ins}} \text{ Ec. 4}$$

Factor de diversidad.- Es el cociente entre la suma de las demandas máximas individuales y la demanda máxima conjunta:

$$f_{div} = \frac{\sum_i D_{max i}}{D_{max}} \text{ Ec. 5}$$

3.3 Consumo eléctrico

Es la energía utilizada durante un periodo T total, es el área bajo la curva de la carga. Significa satisfacer las necesidades presentes o futuras.

Los consumos eléctricos no solo requieren de potencia activa P sino también requieren de Q que es la potencia reactiva.

Factor de potencia.- Es el cociente entre la potencia activa y la potencia aparente, que es coincidente con el coseno del ángulo entre la tensión y la corriente cuando la forma de onda es sinusoidal pura, etc.

$$tg(\varphi) = \frac{Q}{P} \text{ Ec. 6}$$

3.4 Tipos de demanda eléctrica

Los tipos de cliente típicos del sector eléctrico son: industrial, comerciales y residenciales. La demanda comercial tiene fluctuaciones estacionales, provocadas por calentadores y aire acondicionado.

La demanda industrial no tiene muchas variaciones, en el tiempo y depende mucho del tipo de industria y están correlacionadas con factores macroeconómicos.

Dentro de tipos de carga se presentan las cargas pasivas, que son consideradas como cargas controlables porque aplicando control en ellas no causan inconvenientes para el consumidor. Otro aspecto de la utilización de las cargas pasivas es ampliar su utilización no sólo para gestión de carga, sino también utilizar la carga como respaldo de seguridad en la red en lugar de varias generaciones adicionales (reserva en giro), que se supone que son para la seguridad de la red en caso de contingencia. [30] Los dispositivos tales como refrigerador, calentador eléctrico, aire acondicionado, lavadora, secadora, etcétera, todos ellos

son cargas pasivas y tienen la capacidad de ser controlados automáticamente o ser llamados por el operador de red en el evento de la necesidad de desprender carga.

3.5 Demanda eléctrica residencial

La demanda residencial es la que tiene más acentuado el efecto de estacionalidad, y su definición va de la mano de aspectos sociales, climáticos, económicos [26]. La demanda eléctrica residencial puede cambiar de un hogar a otra según el número de artefactos, y a la forma de uso de ellos. A continuación se describe las características de operación de los electrodomésticos más comunes que definen el perfil de la demanda residencial, y su buen uso, esto principalmente para identificar cargas que pueden ser controlables, o analizar la factibilidad de aplicación de gestión de la demanda eléctrica, o proyectos de concientización del uso adecuado de la energía.

Descripción de algunos electrodomésticos

Los electrodomésticos son el fundamento del consumo residencial, toman determinadas categorías de acuerdo a su eficiencia. La escala utiliza un código de colores y letras. La gama va desde el color verde y la letra **A** para los equipos más eficientes, hasta el color rojo y la letra **G** para los equipos menos eficientes [27], en la Figura 13, se muestra esta descripción.




Figura 13 Categorías energéticas tomado de la guía práctica de la buena energía de la Comisión Nacional de Energía - Chile.

La mayoría de los aparatos electrodomésticos excepto equipos de iluminación, tienen vida útil media sobre 10 años, que es beneficioso ya que si se adquiere un equipo tipo A el ahorro a largo plazo es representativo.

No basta con que un electrodoméstico sea eficiente sino también influye mucho el tamaño y las funciones adecuadas. Existen varios electrodomésticos con etiquetado a nivel mundial entre ellos: refrigeradores, congeladores, lavadoras, lavavajillas, secadores de ropa, ampolletas, hornos eléctricos, equipos de aire acondicionado, etcétera.

A continuación se describen algunas características de los electrodomésticos presentes en la mayoría de hogares [27].

Refrigeradores

Es el que más consume electricidad de la vivienda, un 32% del consumo total, aunque su potencia no sea muy grande es como 200W, pero es de uso continuo, ya que solo se desenchufa en instantes muy reducidos, y esto hace que tenga una gran representación en la planilla eléctrica.

Se puede dar un uso eficiente del refrigerador porque a diferencia de los otros electrodomésticos el desempeño del refrigerador depende del lugar instalado, como por ejemplo que exista circulación de aire por la parte trasera, alejada de focos, cocina, radiación solar directa, y a esto sumarle el abrir el refrigerador únicamente de ser necesario.

Lavadora

Después del refrigerador y el televisor es el electrodoméstico que más energía consume, en las grandes ciudades es utilizado entre 3 y 5 veces a la semana por una familia, la mayor parte de la energía se consume en el proceso de calentamiento de agua, entre el 80 y 85%.

En la Figura 14 se muestra el consumo en un ciclo de lavado normal.

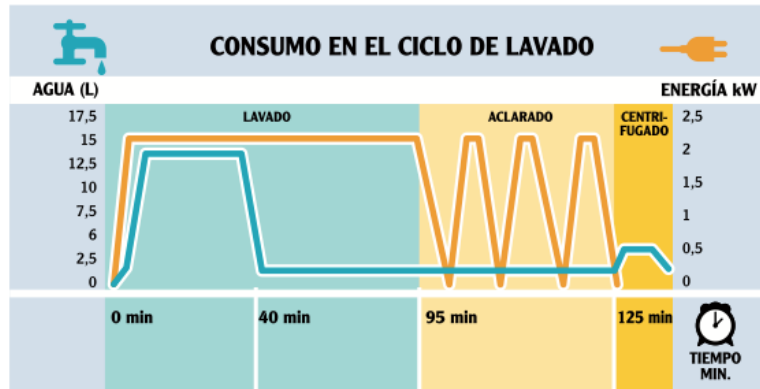


Figura 14 Consumo energético en un ciclo de lavado tomado de la guía práctica de la buena energía de la Comisión Nacional de Energía - Chile [27].

Secador de ropa.

Es un alto consumidor de energía, en la mayoría de los lugares se está incrementando el uso de secadoras, hay dos formas de secado que influyen el consumo; una es por extracción se expulsan tanto el aire frío como el caliente, y por condensación en cambio el aire caliente y húmedo circula por un circuito de condensación que elimina el agua siendo este más eficiente.

Iluminación

Representa el 27% del consumo del hogar. Hay varios tipos de iluminación como: ampolletas incandescentes o convencionales, son las de mayor consumo eléctrico, las más baratas y menor duración (aproximadamente 1000 horas). Ampolletas halógenas, mayor duración que las anteriores, y mejor calidad de luz, hay algunas que usan transformadores de tipo electrónico, disminuyendo la pérdida de energía, con respecto a los convencionales, el consumo final puede reducirse en un 30% inferior al de las ampolletas convencionales. También están los tubos fluorescentes, se basan en emisión luminosa que algunos gases como el flúor, emiten al paso de una corriente eléctrica. Son más caros que las ampolletas convencionales, pero consumen hasta un 80% y duran de 8 a 10 veces más, los tubos de trifósforo o multifósforo dan entre el 15 y 20% más de iluminación que lo estándar.

Ampolletas de bajo consumo, son pequeños tubos fluorescentes, son más costosas que las ampolletas tradicionales, pero producen mayor ahorro en energía que luego se refleja en dinero su vida útil es entre 6000 y 8000 horas. En la Tabla 3, se detalla los tipos de lámparas, su consumo y flujo luminoso.

Tabla 3 Consumo eléctrico en luminarias.

Tipo de Lámpara	Potencia (W)	Flujo Luminoso (lm)	Vida útil (h)
Incandescente	25 a 500	220 a 8200	1000
Halógena	40 a 2000	500 a 50000	2000
Tubo Fluorescente	15 a 48	1150 a 5200	14000 a 18000

Fluorescente Compacta	5 a 55	200 a 4800	8000 a 13000
-----------------------	--------	------------	--------------

Cocinas eléctricas

Las cocinas eléctricas pueden ser de resistencia convencional, de tipo vitrocerámico o de inducción, siendo esta última más eficiente, calientan los alimentos generando campos magnéticos.

Aire acondicionado

Los equipos de aire acondicionado son usados y se ha incrementado su uso principalmente en países con estaciones climáticas muy marcadas, son pocos los hogares que se construyen con sistemas centralizados de aire acondicionado cosa que no ocurre con la calefacción, teniendo que incorporarlos como equipos externos en las fachadas de las casas. Existen sistemas compactos, que tienen el evaporador y el condensador dentro de la misma carcasa, sistemas Split, existe una unidad exterior (condensador), y otra interior (evaporador) conectados por tuberías para que pueda circular el refrigerante. Y los transportables en dos versiones. Los de menor eficiencia son los de pared.

Ventiladores

El movimiento del aire produce una sensación de disminución de temperatura entre 3 y 5 °C y su consumo eléctrico es muy bajo.

Pequeños electrodomésticos

Son pequeños electrodomésticos aquellos que realizan funciones esporádicas así como para batir picar, etcétera, con excepción de la aspiradora tienen potencias bajas, pero sin embargo aquellos que producen calor como la plancha secador tostador tienen potencias mayores.

Televisores y equipos auditivos

La mayoría de hogares tienen al menos un televisor, la potencia en realidad es pequeña pero por el tiempo de uso puede reflejarse en consumos considerables, de igual forma poseen al menos un equipo de audio y un DVD, y actualmente equipos de pantallas cada vez más grande y de mayor potencia. Las pantallas LCD ahorran hasta 37% de la energía cuando están funcionando y un 40% en modo de espera [28].

3.6 Características de la demanda eléctrica

La caracterización de la demanda es un desafío que requiere principalmente de una amplia base de datos. Algunos proyectos internacionales enfocan su investigación en la demanda eléctrica, como pasos previos para implementar controles de demanda, uno de ellos es la propuesta de control de demanda para el sector residencial en Reino Unido [29], que parte de la caracterización de la demanda. En la Figura, se muestra la forma en la que se caracteriza la demanda para un sector del Reino Unido.

Para la caracterización de la demanda primero obtienen un registro de datos de potencia, factor de potencia, temperatura dentro y fuera de hogares, muestreados cada minuto por cuatro semanas, para esta etapa se usaron treinta casas de muestra. Como segunda etapa realizan una primera interpretación del perfil de la demanda, mediante el uso de encuestas identifica los tipos de vivienda, tamaño de hogares, patrones de comportamiento, ingresos económicos. Mientras que de los registros de medición instalados en las casas se obtiene el consumo eléctrico, la demanda máxima, el factor de carga, duración de la demanda, carga promedio del día, aparatos de uso principal, aparatos de menor consumo, factor de

influencia de la demanda. En función a esos datos se obtiene, varios tipos de perfiles, destacando aquel grupo en el que habitan personas durante todo el día, y el otro grupo que es de aquellos que el mayor tiempo están fuera de sus hogares. En función del grupo y sus características se selecciona un método de control de demanda. La caracterización de la demanda es el paso previo a la aplicación de sistemas de gestión de demanda.

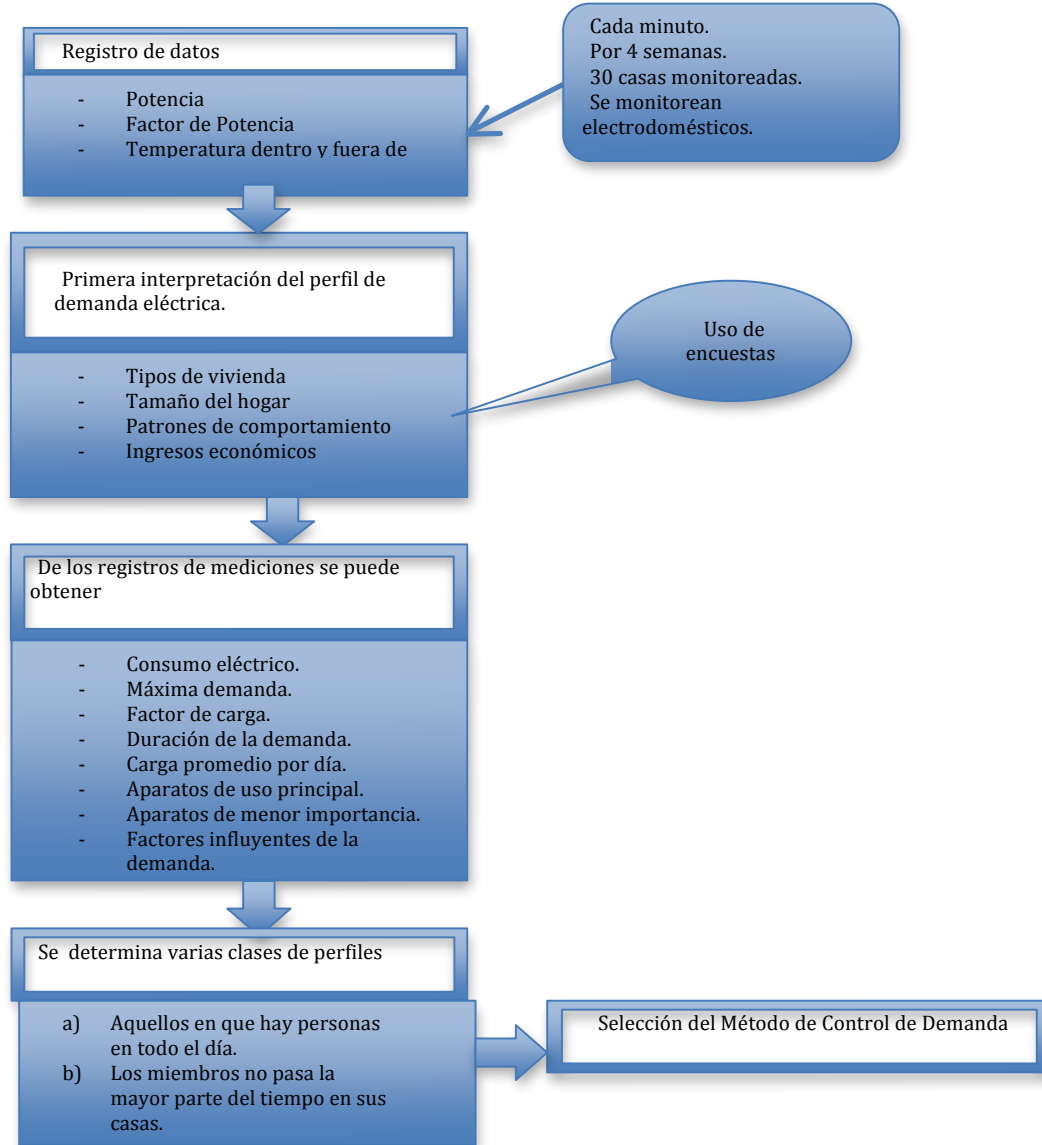


Figura 15 Caracterización de la demanda, desarrollo en función de la información de [29]

Trabajos como el propuesto por Kim [32], que realizan la construcción de un perfil de carga virtual en inglés, aseguran que la reconstrucción, o generación de perfiles virtuales de carga requiere fundamentalmente de registros o base de datos, por lo que instalaron medidores inteligentes o medidores de lectura automática en inglés Automatic Meter Reading (ARM) en determinadas casas de una zona, y recogen datos cada quince minutos, sin embargo no todas las casa, cuentan con esta instrumentación, a este grupo se las llama nARM, por no disponer de medidores automáticos, por el contrario únicamente disponen de medidores tradicionales que registran consumos mensuales [32].

Tanto AMR y nAMR, son muy importantes en la creación de perfiles de carga virtual ya que en función de los perfiles registrados por ARM, se pueden construir los perfiles virtuales que son específicamente para aquellas casas nARM.

Como se ve en la Figura 16, las empresas eléctricas normalmente cuentan con dos tipos de medidores, los primeros que son los medidores de lecturas automáticas, normalmente instaladas en casa de mayor consumo eléctrico mensual, y el otro tipo de medidores los de lectura no automática que son los tradicionales.

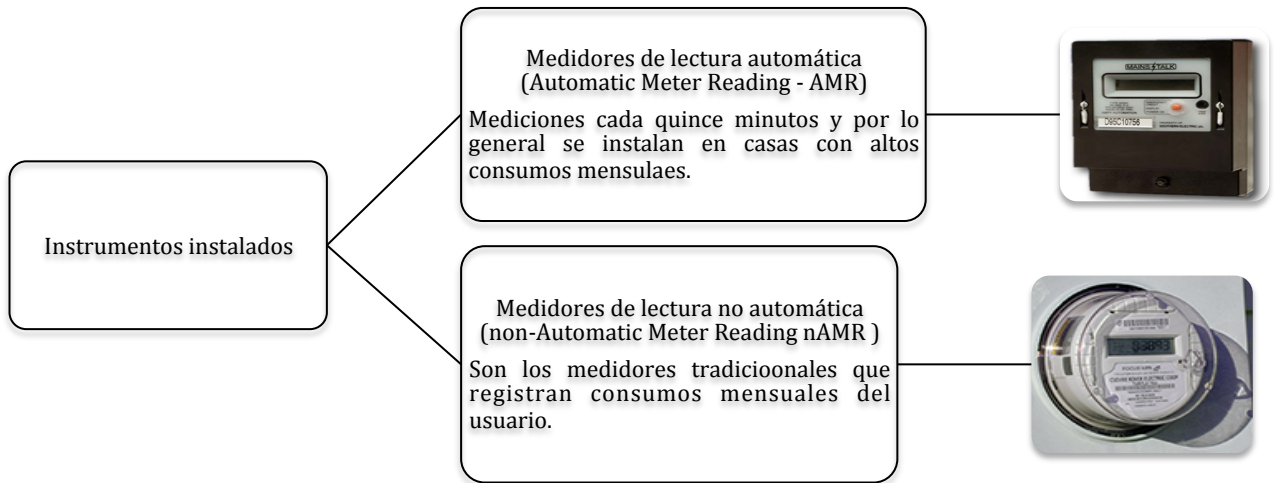


Figura 16 Tipos de medidores instalados en las residencias.

El procedimiento de la generación del VLP de los nARM se muestra en la Figura. Usando las mediciones de las casas ARM, y el consumo mensual de las nARM, primero ejecutan un pre-procesamiento de datos, filtrando datos erróneos y normalizándolos.

Luego hacen una clasificación de tipos de consumos mensuales tantos ARM como nARM, y se establecen grupos. Luego de los datos ARM se identifica un perfil típico del grupo, y se genera el VLP total de la zona.

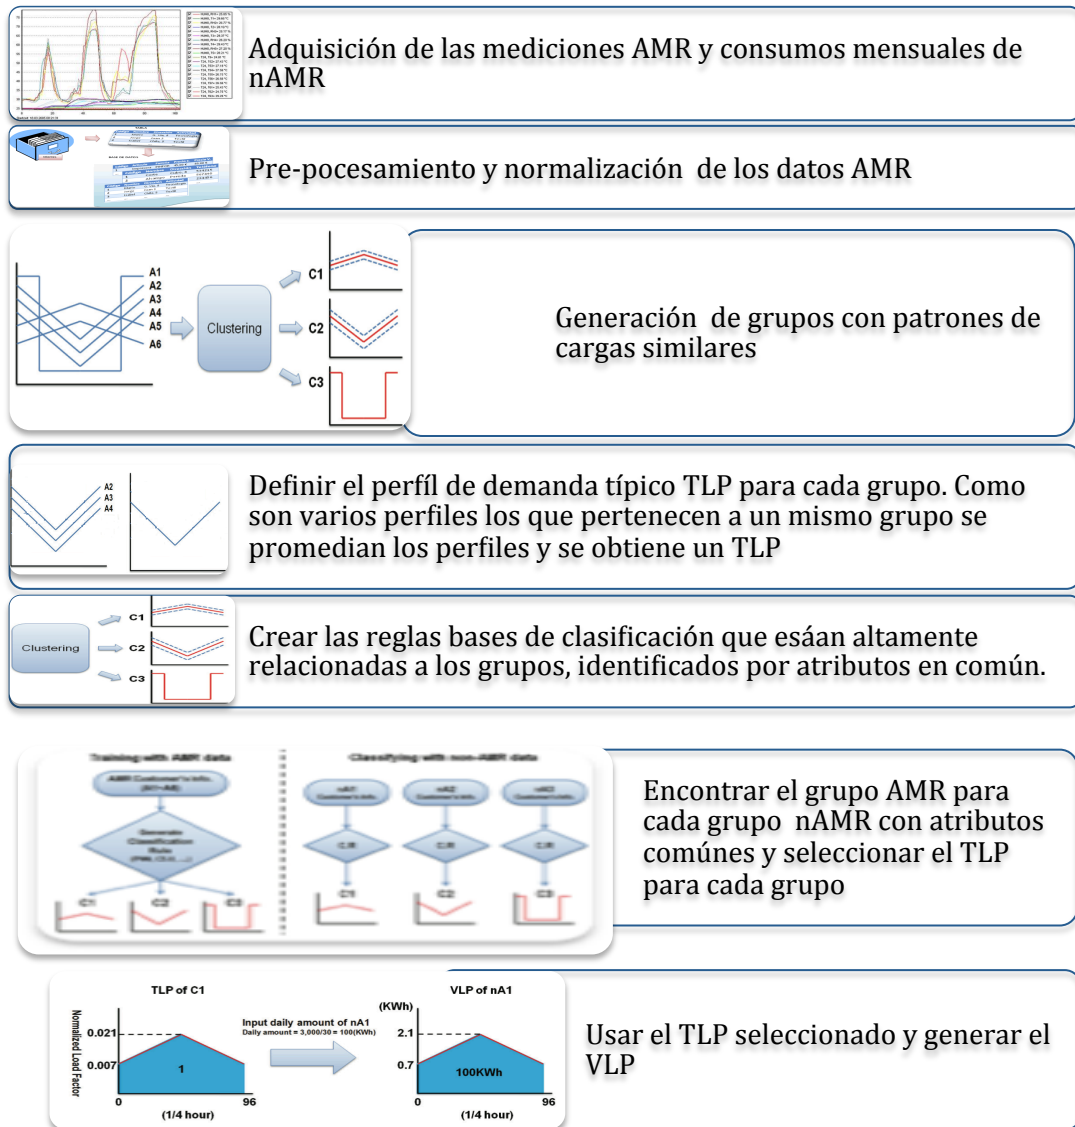


Figura 17 Modelo conceptual de generación de perfil de carga virtual.

3.7 Demanda eléctrica en comunidades

Las comunidades rurales y los centros urbanos tienen características diferentes, la mayoría de estudios sociales coinciden en que en las comunidades rurales por lo general son; regiones donde la industria no está desarrollada y por lo tanto, hay la presencia de una débil actividad económica, la mayoría viven de la agricultura o la ganadería, con problemas de salud y educación, otra característica de las comunidades rurales es la infraestructura deficiente, a diferencia de las ciudades, las comunidades rurales suelen contar con calles de tierra y sufrir la carencia de alumbrado público, servicio de conexión a internet u otras prestaciones. Los servicios públicos, por lo tanto, se limitan a lo mínimo e indispensable, y la presencia masiva de migración. Pero es justamente en estas comunidades donde proyectos de intervención de comunidades y perdurables en el tiempo se puede aplicar debido a que tienen una vida más comunitaria y una mayor solidaridad social.

La tercera parte de la población mundial carece de electricidad y los sistemas de electrificación basados en fuentes de energía renovables han demostrado ser adecuados para proveer de energía eléctrica a comunidades aisladas de forma autónoma.

3.7.1 Características del perfil de demanda en comunidades aisladas

En la Figura 18 se hace una comparación entre la demanda eléctrica en zonas urbanas con el de comunidades aisladas, en base a sus características.

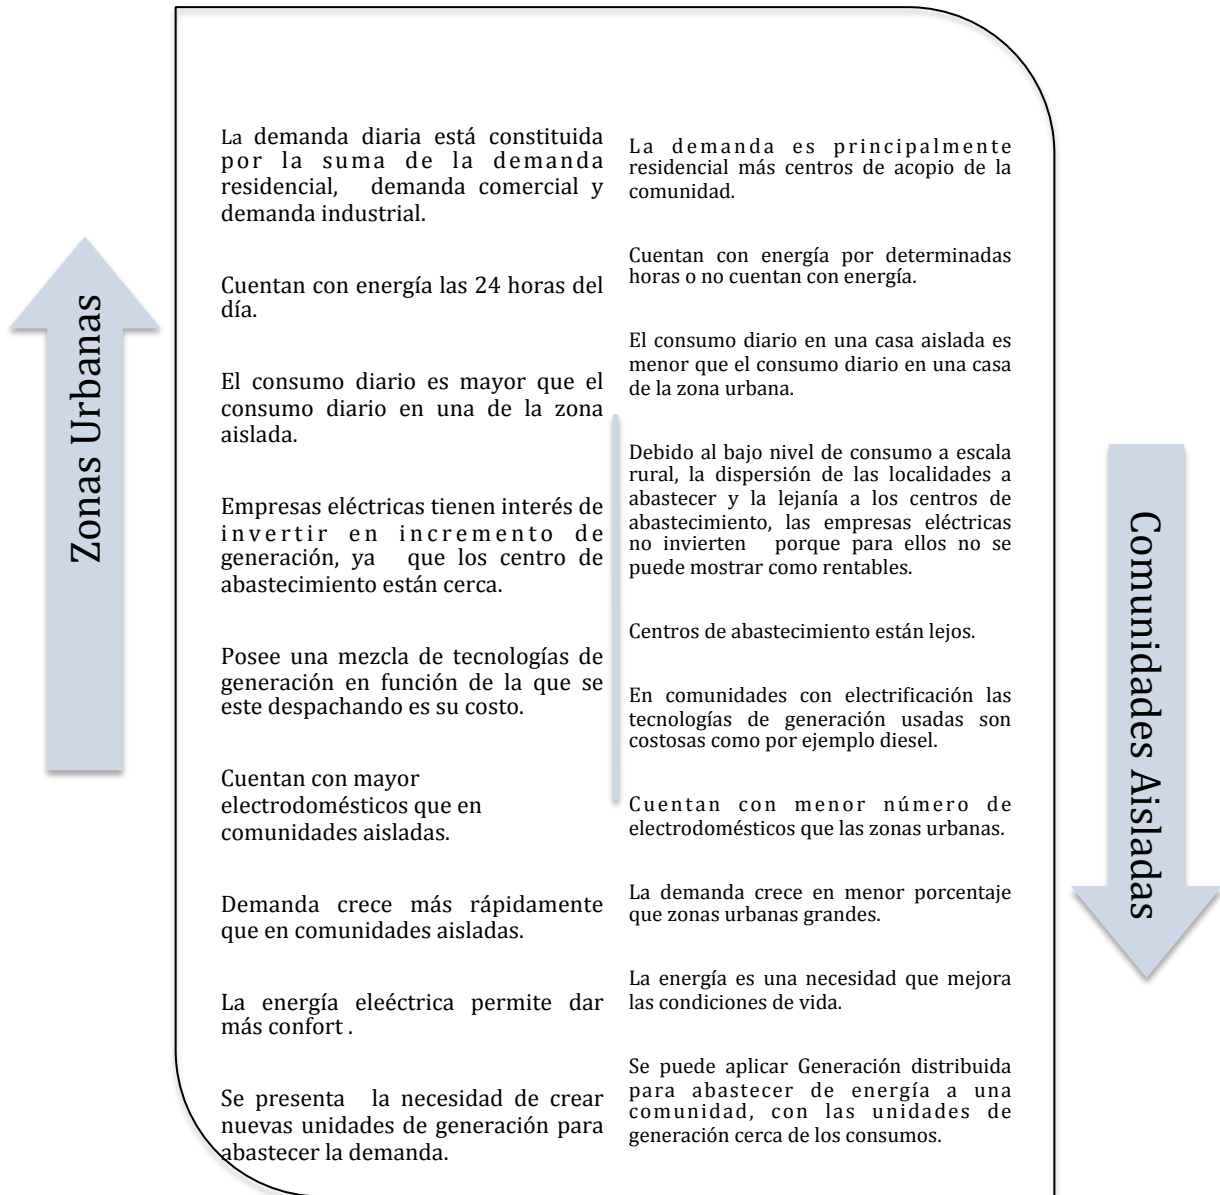


Figura 18 Comparación de la demanda eléctrica en zonas urbanas y comunidades aisladas.

En la Figura, se muestra el perfil de demanda eléctrica de una comunidad aislada que dispone de energía por determinado tiempo, mientras que en la Figura 20 se muestra el perfil de demanda de una comunidad con energía las 24 horas. En la Figura 21, se distingue la demanda diaria de una zona urbana.

Se puede observar que en los perfiles de comunidades se distingue un único peak de consumo, mientras que la de una comunidad con suministro ininterrumpido se producen dos uno en la mañana y otro en la noche.

Al comparar los dos perfiles el de la comunidad con suministro las 24 horas (Figura 20) y el de una zona urbana (Figura 21), se puede distinguir que los perfiles no son parecidos principalmente porque el de la comunidad tiende a ser más plano con la presencia de un único valor de potencia máxima en el horario de la noche, mientras que el de la zona urbana presenta dos uno en la mañana y otro en la noche, además se puede notar que el de la comunidad tiene mayores variaciones comparado con el urbano.

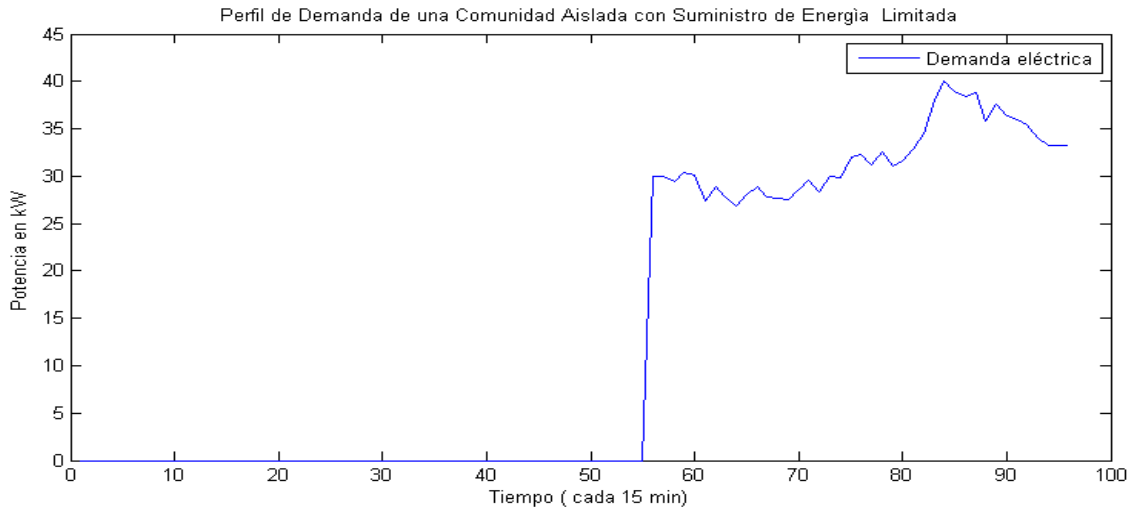


Figura 19 Perfil de demanda eléctrica de la comunidad aislada Huatacondo [89]

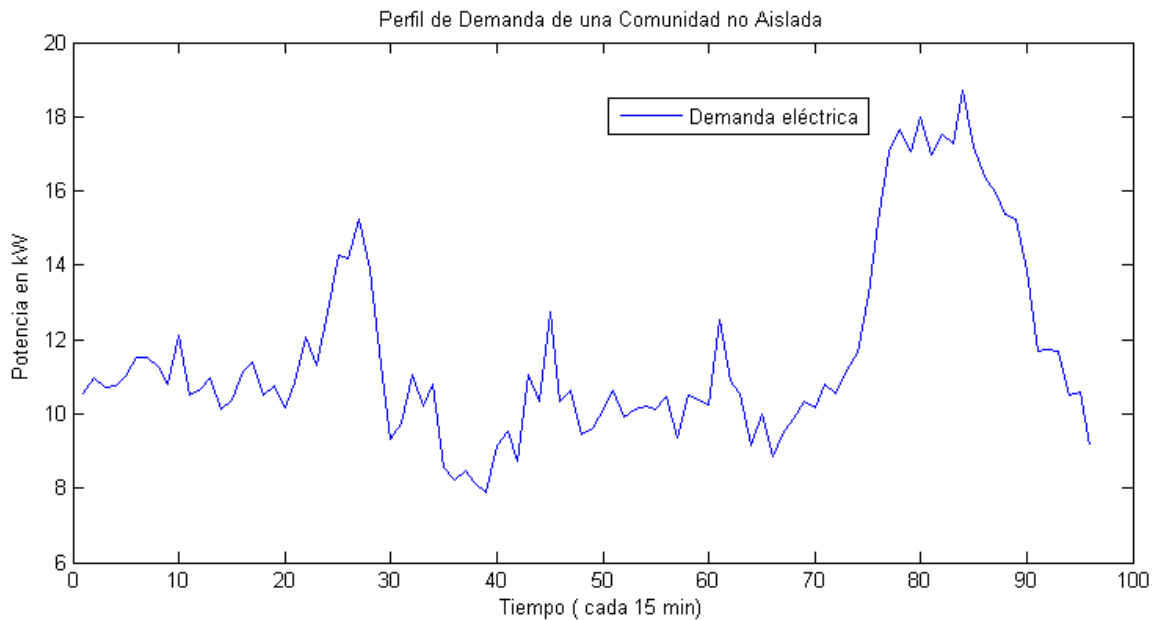


Figura 20 Perfil diario de demanda eléctrica de una comunidad aislada Huatacondo con engría las 24 horas [89]

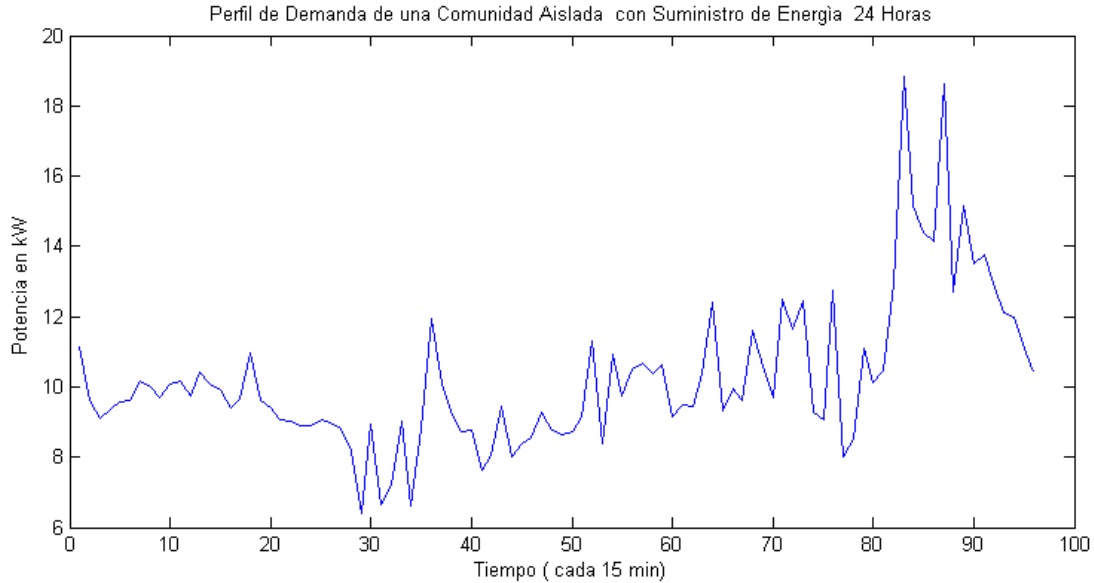


Figura 21 Perfil diario de demanda eléctrica de una zona urbana [90]

3.7.2 Electrificación en comunidades aisladas

Los proyectos de electrificación en comunidades aisladas, o en comunidades rurales, no cumple con una necesidad básica incluye otros beneficios para la las comunidades como; la integración de los sectores rurales al desarrollo económico nacional, frenar la migración rural-urbana, aumentar las posibilidades de generación de ingresos al tener medios de producción más tecnificados sobre la base de la energía eléctrica, mejorar nivel socio cultural de sus habitantes.

La electrificación rular abarca sistemas de electrificación aislados y autónomos que han demostrado ser adecuados para proveer de energía eléctrica a comunidades rurales, principalmente introduciendo energía renovable.

Hoy en día con los nuevos desarrollos en el sector eléctrico y el de la innovación en este campo, no se busca únicamente electrificar las zonas aisladas sino hacerlo usando nuevas tecnologías insertando generación renovable y aprovecharse de sus beneficios, y en este marco, incentivar la ejecución de nuevas propuestas orientadas en generación distribuida, como generadores virtuales, micro-redes.

3.8 Gestión de la demanda eléctrica, Demand- Side Managment (DSM)

El sistema de gestión de la demanda es la planificación, implementación, y monitoreo de actividades, diseñadas para influir en el uso de la electricidad en los clientes de tal forma que produzcan cambios deseados en la manera de utilización de la energía. La mayoría de DSM incluyen: gestión de carga, nuevos usos, estrategias de conservación, electrificación, clientes y ajuste en el mercado [33].

El DSM redistribuye la carga, pero no necesariamente reduce la energía total consumida. La duración de los períodos de recuperación de carga depende del proceso interrumpido y la naturaleza del almacenamiento. La gestión de la demanda es un viejo tema, que tradicionalmente es utilizada para suavizar la curva de demanda para maximizar la eficiencia de la generación convencional cuando puede ser controlable y predecible [30].

Hay una serie de aspectos que pueden acelerar la penetración del DSM como; el cambio climático, el desarrollo de la información y la comunicación, los envejecimientos de la infra-estructura eléctrica, la perspectiva de aumentar la eficiencia del funcionamiento del sistema, y ofrecer opciones a los consumidores con respecto al uso de la electricidad y la prevención de los subsidios cruzados entre los consumidores [26].

Los programas de gestión de la demanda llevan a que los operadores de redes puedan mejorar la calidad de suministro, con mayor fiabilidad, eliminar horas punta y desconexión de carga innecesaria sobre todo en el sector doméstico [30].

El DSM busca beneficiar tanto a las empresas de servicios como a los clientes de energía, para el primer caso elimina o retrasa la construcción de más unidades de generación, en cambio para los clientes, el DMS ofrece la oportunidad de reducir su factura por energía eléctrica, en caso de clientes industriales se puede traducir en menor costo de producción, y en los clientes domésticos significa ahorro que podría ser usado en otros gastos del hogar. A menudo el DSM no solo busca cambiar el perfil demanda a una forma plana sino también a reducir la demanda global mediante la adaptación de diversas técnicas de eficiencia energética [32]

3.8.1 Beneficios del DSM y las oportunidades futuras

Uno de los beneficios de la gestión de la demanda es la reducción de incrementos de generación, en lugar de hacer frente a la escasez de energía, mediante la instalación de generación que se utiliza con muy poca frecuencia, puede ser posible identificar los hogares que estarían dispuestos por cierto pago, a renunciar o consumir con poca frecuencia determinadas cargas.

El DSM se podría utilizar para gestionar restricciones de la red a nivel de distribución. En general, el DSM podría traer un espectro de beneficios potenciales en términos de (i) el aplazamiento de las nuevas inversiones en la red, (ii) el aumento de la cantidad de generación distribuida que se puede conectar a la infraestructura de la red de distribución existente, (iii) el alivio de la congestión en las subestaciones de distribución, (iv) la gestión de corte de simplificación y la mejora de la calidad y seguridad del suministro a los clientes críticos, y (v) reducción de las emisiones de carbono correspondientes [26].

Hay un tema en particular emergente asociado con el aumento de la carga de las subestaciones de distribución existentes en las zonas urbanas, en países en donde las estaciones climáticas son muy marcadas, debido a un aumento significativo de las cargas como aire acondicionado. EL DSM se podría utilizar para gestionar este incremento, y también para aumentar la capacidad de carga de los transformadores. El problema es que la limitación de espacio dentro de las subestaciones limitarían considerablemente las posibilidades de sustitución de los transformadores sobrecargados existentes por otros nuevos de mayor capacidad. En este caso, hay una oportunidad para la aplicación de hielo-enfriamiento, en instalaciones destinadas al uso de la electricidad para producir hielo durante la noche, que luego puede ser usada para enfriar el transformador en las condiciones de máximo consumo diario.

3.8.2 Técnicas de Gestión de la Demanda DSM

DSM se compone de varios programas que tienen como objetivo el control de las cargas en una forma de beneficiar tanto a consumidores y empresas de servicios públicos sin ningún tipo de inconvenientes para ambos.

La mayoría de las técnicas de DMS que se ponen en práctica tratan de animar a los usuarios de energía a modificar su perfil de demanda y se logra generando incentivos arancelarios, permitiendo programarse a los usuarios en sus actividades en los períodos de menor consumo disminuyendo el consumo en períodos de hora punta. En algunos casos los incentivos negativos o castigos son también utilizados [32].

Hay tecnologías para su implementación del DSM, que han sido desarrolladas y que han sido puestas en práctica, a continuación se revisan brevemente las mismas:

Gestión de carga (Load Management - LM)

Es uno de los programas DSM que han sido ampliamente ejecutados en la mayoría de países, ya que controla directamente la carga. El principio de LM es que el beneficio del usuario se incrementa durante el período que está fuera de la hora punta, por lo tanto las cargas controlables son de gran importancia en LM. Incluyen programas de múltiples tarifas eléctricas que por cambio de uso de energía en las horas de menor uso y recortar el horario punta de la curva de demanda diaria. Hay otros programas LM con efecto diferente que mejoran las características de la carga tales como flexibilidad y factor de carga beneficiándose tanto consumidores y usuarios de la red. Los programas más populares en gestión de carga en áreas domésticas son; iluminación efectiva, remplazo de dispositivos existentes y múltiples tarifas [30].

Dentro de la gestión de carga hay varias aplicaciones en lo que se refiere al control directo de carga doméstica que consiste en aplicar programas a los equipos para que sean apagados o controlados por ciclos de tiempo relativamente cortos. Esto se aplica a piscinas, sistemas de aire acondicionado, calefactores, bombas de piscina. Los sistemas receptores son instalados para habilitar las comunicaciones desde la empresa de distribución o desde las instituciones de control.

Las comunicaciones a menudo son por señales de radio o por comunicación por el sistema de energía, PLC (Power Line Carrier).

Los ciclos de apagado o desconexión de carga son efectuados, en un número limitado de horas, ocasiones limitadas. Típicamente los usuarios libres pueden operar los equipos cuando estos no están bajo control directo. Los controles inteligentes tienen memoria para reconocer cuántos equipos han sido encendidos y programan una frecuencia de ciclo diferente, también todos los participantes proveen una reducción similar de carga. Los clientes quienes toman parte en los esquemas de control directo son compensados con una reducción en las cuentas de energía [2].

Los proveedores de energía influyen en la redistribución de la demanda y el tiempo de uso de electricidad, por medio de la gestión de carga de sus clientes. El control de carga de algunas familias lleva a una forma continua el perfil de demanda. Los tipos de técnicas de gestión de carga son: nivelación de carga, control de carga, incentivos arancelarios y sanciones.

Nivelación de carga.- Las formas más clásicas de nivelación de carga se muestran en la Figura 22, que presenta tres casos de nivelación, la primera por recorte en el horario punta, otra por llenado de los valles en donde hay menor consumo, y la tercera que es el desplazamiento de carga que produce los mismos efectos de las dos anteriores es decir recortar el horario punta y rellenas en los períodos de menor consumo.

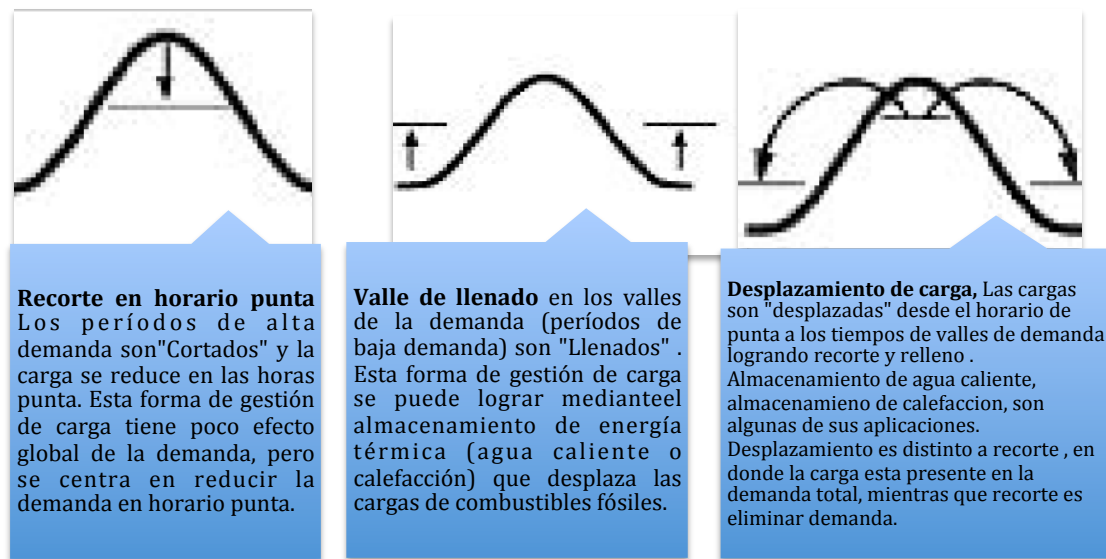


Figura 22 Nivelación de carga desarrollado con la información del módulo 14 de DMS, de sustainable energy regulation and policymaking for Africa [32]

Control de carga.- El control de carga es cuando las cargas (por ejemplo, calefacción, refrigeración, ventilación e iluminación) se pueden encender o apagar, a menudo de forma remota. Las empresas de servicios públicos tienen acuerdos con los clientes interrumpibles de acuerdo a eso hay tarifas.

Incentivos arancelarios y sanciones. – Consiste en fomentar un determinado patrón de uso de en función de incentivos arancelarios donde el cliente obtiene tasas de precio por el uso de energía.

Estos incluyen:

Tiempo de uso, donde las tasas de servicios públicos tienen cargos diferentes para el uso de energía durante períodos diferentes, es decir un costo mayor durante horario de punta alertando así al usuario hacer mayores actividades cuando no es horario punta y el costo de la energía es menor.

Factor de carga, donde los usuarios son penalizados por tener un factor de potencia por debajo de un umbral que por lo general es de 0.9 - 0.95.

Precios en tiempo real, donde los precios varía según el tipo de la servicio de la carga (de forma continua o por hora).

Conmutación de carga (calefactores) nocturna

Conocida la operación del sistema de generación en base a costo marginal nocturno. En Inglaterra hay siete tarifas desarrolladas para apoyar el almacenamiento de calor nocturno, lo cual ha llevado al incremento doméstico nocturno de cargas, dando un mayor balance en la generación de energía a lo largo del día. Como la calefacción por gas se ha vuelto más popular hoy en día el 10% de los consumidores tienen medidores con tele-conmutación por radio.

Limitación de carga

Los limitadores de carga pueden ser tomados por clientes en forma individual. El nivel en lo que quieran limitar su consumo depende de las condiciones del sistema. Estos sistemas suelen ser escogidos por los

propios usuarios y deciden qué consumo quieren postergar. Asociado a este está el precio por hora de uso, donde los precios de hora uso son diseñados para reflejar más la estructura de costos de operación e inversión donde los precios son más altos en horario punta y son más bajos fuera del período punta, la clave es diseñar tarifas de duración de periodos individuales asociadas a precios.

Programas industriales y comerciales

Los programas para la administración de la demanda punta están disponibles para los consumidores comerciales e industriales. Popularmente estos programas son interrupción de cargas para prestar servicios complementarios, como por ejemplo aumento de la reserva en giro, y mejorar la confiabilidad del sistema. Esta desconexión de carga no es un ejercicio diario pero es usado para respaldar los sistemas de desconexión de generación o instalaciones de la red.

Los clientes comunes que participan de estos esquemas son: refinerías, mineras, plantas de tratamiento de agua, siderúrgicas. Hay también programas para clientes comerciales donde la carga es controlada usando sistemas de control para sistemas de aire acondicionado, calefactores, control de iluminación, sistemas de refrigeración.

Oferta de demanda

Los programas de oferta de demanda están disponibles cuando los usuarios están dispuestos a reducir o renunciar a sus consumos de energía por precios fijos predeterminados. Una tecnología que permite esto son los termostatos programables con los cuales funcionan los aires acondicionados y los sistemas de calefacción. Los termostatos pueden ser programados adoptando diferentes sets, dependiendo de los niveles de precio de la electricidad sin embargo los termostatos pueden ser programados para cambiar sus sets con las estaciones del año, pueden también tener una notificación futura para alertar a los residentes de llamados de acción.

Varios de estos programas están basados en internet y están en desarrollo, el consumidor obtiene información de las tasas de los precios a través de internet y toma acciones apropiadas para administrar los puntos de demanda máxima.

Control integrado

El incorporar gestión de carga, a un sistema automático en los hogares, con interacción con controles esclavos en ciertas aplicaciones, es una ruta clave para lograr aplanar el perfil de demanda residencial. Pese a que estos sistemas ofrecen mayor inteligencia en el control de demanda, un limitante son los altos costos de estas dotaciones, para obtener un beneficio financiero para el jefe de hogar se tendría que ir incluyendo desarrollos que incorporen la optimización de almacenamiento térmico, obteniendo una reducción en las tarifas eléctricas.

Los medios de comunicación para el control del aparato han sido desarrollados principalmente para el mercado de automatización del hogar, especialmente para dispositivos audio-visuales. Estas podrían formar la columna vertebral de la estructura de comunicación necesarios para que aparatos puedan comunicarse con una central de control de unidades y posiblemente uno con el otro.

Simple desconexión por ejemplo conmutar el apagado de los elementos calentador por periodos menores a 60 segundos es una alternativa durante periodos de crisis y es factible reducir demanda en horario punta, que puede ser aplicable por ejemplo en hornos, cocinas eléctricas, calentadores de inmersión, lavadoras y lavavajillas. M. Newborough desarrollaron un software simulando la operación de control central con la modulación de la demanda que investigaron [29]

Equipos smart-metering

Los Smart-metering son de importancia en DSM. Ya que los usuarios conocen el valor de la electricidad en tiempo real en función de la hora y localización. Los grandes clientes pueden atarse a precios de electricidad en sus sistemas de administración de energía, debido a grandes diferencias de precios en horario punta y no punta, produciendo grandes recortes de energía en horario punta. Para esto se requiere de equipos inteligentes que faciliten la implementación de un DSM.

Antes que los sistemas de respuesta de demanda puedan ser implementados a gran escala en el sector residencia hay algunos desafíos técnicos que requieren ser resueltos (infraestructura de las telecomunicaciones, infraestructura de medición, respuesta de la demanda, etcétera). Es probable incluir algunos sistemas de administración de demanda que se basen en tecnología inalámbrica, para que automáticamente respondan a señales de precio tomando en consideración las preferencias de los dueños de casa, en cuanto la relación costos versus confort.

Regulación de frecuencia

La frecuencia es medida directamente del balance entre el sistema de generación y la demanda, y debe permanecer constante. Cuando ocurren desconexiones de importantes bloques de generación se provoca una caída de frecuencia, para que esta se mantenga constante y en valores razonables, se requiere de desconexión de bloques de carga, en estas desconexiones participan por ejemplo empresas fundidoras de aluminio.

Recientemente se han iniciado iniciativas para investigar tecnologías que puedan ser incorporadas a los equipos eléctricos que permitan ser desconectados y así contribuir en la regulación de frecuencia del sistema, algunos equipos eléctricos que son flexibles podrían incorporar esta tecnología e incluyen sistemas industriales o comerciales de aire acondicionado calefacción y refrigeración .

Métodos de modulación de la demanda.

Este ítem es de considerable atención y se centra en la reducción del peak de demanda y las demandas coincidentes máximas. Parten de la identificación de las actividades responsables de la potencia (en viviendas de Reino Unido el cocinar y lavar), siendo muy considerables cuando estas se juntan. Luego la identificación de los electrodomésticos que lo producen (hornos, calderas, lavadoras, secadoras, lavavajillas).

Hay cargas que se puede modular muy poco como las cargas de consumos menores así como por ejemplo televisores, videograbadoras, equipos de refrigeración. La iluminación doméstica, al ser controlable es poco probable producir una reducción de los horarios punta, sin embargo el cambio de incandescente por sistemas, puede tener más impacto.

Algunas otras aplicaciones como hervidor eléctrico, tostadoras, microondas secadoras, productos de limpieza, son consideradas no-interrumpibles, porque no son definidos sus horarios de usos y por el tiempo de encendido en el orden de pocos minutos, pero si pueden ser contempladas en sistemas de alertas que le anuncian al usuario cuando se puede incrementar consumos y cuando disminuir.

Las principales opciones para modelamiento de la demanda eléctrica para una vivienda son:

1.- Controlar el funcionamiento de los calentadores eléctricos instalados en los aparatos de manera más consiente.

2.- Utilizar algún tipo de control integral para mejorar el efecto coincidente de demanda por aplicaciones individuales en periodos de mayor consumo eléctrico.

3.- La aplicación de técnicas de almacenamiento térmico.

4.- Simplemente evitar el uso de electricidad para calefacción, y en su lugar usar gas.

De todas estas opciones la número uno es la más atractiva por ser económica de implementar [29].

Como se mencionó anteriormente la gestión de la demanda busca aplanar el perfil de demanda, y no necesariamente disminuir el consumo [32].

3.9 Discusión

El perfil de demanda de una zona, se ve afectado por el constante desarrollo económico, alto nivel de electrificación, uso ineficiente de la energía, empleo de equipos obsoletos, malos hábitos en el uso de la energía eléctrica, tarifas sin señal de costo. En lo que se refiere a cambios en la demanda diaria residencial son producidos por; días laborables, fines de semana, días festivos, el régimen educativo, características ambientales como la temperatura, que influyen en las estaciones climáticas, los perfiles residenciales además son diferentes de un hogar y otro dependiendo de las condiciones económicas de cada casa. Además los perfiles de demanda no son los mismos en zonas rurales que residenciales esto principalmente por las condiciones de vida de cada sector. La mayoría de estudios confirman que el perfil de demanda residencial eléctrica varía diariamente y estacionalmente.

Los electrodomésticos y su forma de uso definen el perfil de demanda en una casa, es por eso que en este capítulo se analizó la forma de operación de los electrodomésticos más usados para que luego permita obtener una idea clara de aquellos que producen mayor consumo, e identificar incluso los electrodomésticos en los que se podría intervenir en caso de aplicar controles de cargas domiciliarias.

En base a proyectos implementados en Inglaterra se puede concluir que la caracterización de la demanda es un desafío que requiere principalmente de una amplia base de datos, registros de potencias, factores de potencias, temperatura, además el uso de encuestas para poder determinar tipos de vivienda, tamaño del hogar, patrones de comportamiento, todo esto permite obtener datos importantes para su caracterización, y posteriormente seleccionar un método de control de demanda.

El objetivo principal del DSM es de redistribuir la carga, pero no necesariamente reduce la energía total consumida, pero en la mayoría de proyectos en la gestión de la demanda se incorpora también una reducción de consumo energético. EL DSM, es un aspecto importante en los sistemas eléctricos que puede traer beneficios como, el aplazamiento de las nuevas inversiones en la red, aumento de la cantidad de generación distribuida que se puede conectar a la infraestructura de la red de distribución existente, alivio de la congestión en las subestaciones de distribución, la gestión de corte, la mejora de la calidad, seguridad del suministro a los clientes críticos de carga, y reducción de la emisión de carbono.

La mayoría de las técnicas DMS que se ponen en práctica tratan de animar a los usuarios de energía a modificar su perfil de la demanda y se logra a través de incentivos que pueden ser de tipo arancelarios. En algunos casos los incentivos negativos o castigos pueden surgir, solo cuando los clientes de la energía estén dispuestos a disminuir o dejar de usar determinadas cargas por ciertos tiempos a los que estaban acostumbrados, por alguna motivación, se puede ejecutar una gestión de demanda.

CAPÍTULO 4

MODELOS DE PREDICCIÓN A CORTO PLAZO DE LA DEMANDA ELÉCTRICA

4.1 Introducción

La predicción de la demanda eléctrica es importante en la planificación, análisis, y operación de los sistemas eléctricos, permitiendo en micro-redes con energías renovables mejorar la gestión de los recursos renovables y convencionales, y así obtener ahorro económico.

En un sistema de energía convencional las variaciones de cargas pueden ser neutralizadas o mitigadas por efectos de otras, y por lo tanto el perfil de demanda presenta menos variaciones. En cambio, en sistemas con tamaño más pequeño como micro-redes causan efectos significativos al agregar o quitar carga, dando lugar a más variaciones en el perfil de demanda de la micro-red. Por lo tanto, la predicción de la demanda en micro-redes es más compleja, en comparación con la demanda de sistemas convencionales.

Varios estudios se enfocan en determinar factores y variables más influyentes en la predicción de la demanda a corto plazo (STLF Short-Term Load Forecasting). Setiawan [34] determina como factores más representativos: el tiempo, efectos aleatorios y días irregulares.

El tiempo, es de importancia en STLF, dado que la demanda eléctrica durante el día es diferente a la demanda en la noche, y la demanda durante los días de semana difiere de la demanda durante los fines de semana. Sin embargo, todas estas diferencias tienen carácter cíclico, ya que la demanda eléctrica de un determinado día de la semana y tiempo, puede tener igual valor que la demanda en una fecha diferente pero con igual día y tiempo. De igual forma los efectos aleatorios, son de importancia en un sistema de energía, por estar continuamente sometidos a perturbaciones aleatorias y fenómenos transitorios, como huelgas, cierre de las instalaciones industriales y programas especiales de televisión que no se conocen a priori, y afectan al perfil. Por último el día irregular, se refiere a los días festivos, días de fiesta consecutivos, y los días anteriores y posteriores a las fiestas, los días con condiciones climáticas extremas o el cambio repentino del tiempo y los días de eventos especiales.

Trabajos como [35] [36] destacan el uso de variables exógenas como: temperatura, velocidad del viento, humedad, nubosidad, como influyentes en la predicción de la demanda a través de estudios de correlación. Con el apareamiento de mercados eléctricos, aparece la variación del precio de la electricidad como una variable influyente en el uso de la energía eléctrica, y por ende en la predicción de la demanda a corto plazo, a su vez trabajos como [37] consideran como entrada a su modelo la señal de precios de electricidad, o como [38] que utilizan para la predicción de la demanda el precio de la energía en tiempo real.

La relación entre la carga eléctrica y los factores exógenos es compleja y no lineal, por lo que es muy difícil ser modelada a través de técnicas tradicionales como regresión lineal (LR Lineal Regresor), modelos autorregresivos de media móvil (ARMA Auto Regressive Moving Averagemo), métodos de suavizamiento exponencial, filtro de Kalman, etcétera. Desde otro punto de vista varias técnicas de inteligencia artificial son usadas para la estimación de carga a corto plazo (Short-Term Load Forecasting STLF), entre estos métodos, las redes neuronales artificiales (ANN Artificial Neural Network) han recibido la mayor parte de la atención. Las RNA que se han utilizado con éxito para STLF se basan en multi perceptrones, redes de funciones de base radial (RBF Radial Basis Function), redes adaptivas neuro difusas (ANFIS Adaptative Neuro Fuzzy Inference Systems).

En este capítulo se presenta el estado del arte actual de los modelos de predicción de demanda eléctrica, a corto plazo, inicialmente se generaliza los tipos y métodos de estimación más populares de demanda eléctrica. Seguido se detalla los distintos trabajos realizados con la descripción de las técnicas usadas, poniendo mayor énfasis al uso de redes neuronales porque es en esta técnica en la que se enmarca esta tesis. Luego se describe los criterios de evaluación de los modelos de predicción, señalando los indicadores estadísticos escogidos para la evaluación de los modelos propuestos finalmente se muestran las discusiones de este capítulo.

4.2 Tipos de predicción de la demanda eléctrica

El objetivo de la predicción de la demanda de energía eléctrica (o carga) es obtener valores futuros del consumo eléctrico en función de los valores pasados y de algunas variables influyentes. Se puede clasificar en cuatro tipos de predicción con respecto a la ventana de tiempo futuro de la tarea de predicción [34], para ser usadas en: planificación, operación o pre-despacho.

A largo plazo (Long-Term Load Forecasting LTLF). -Por lo general son predicciones de uno a diez años, que se utiliza para identificar las necesidades para la planificación de la generación, para el incremento e inversión.

A mediano plazo (Medium-Term Load Forecasting MTLF). -Por lo general son predicciones entre varios meses a un año, y se utilizan para asegurar que la seguridad y las limitaciones de capacidad que se cumplan en el mediano plazo.

A corto plazo (Short-Term Load Forecasting STLF). - Son predicciones de un día, se utiliza para ayudar a la planificación, pre-despacho y la participación en el mercado.

A muy a corto plazo (Very Short-Term Load Forecasting VSTLF). - Son predicciones de horas y minutos por delante usado para ayudar a la comercialización de la energía.

Dada la identificación de los tipos de predicción esta investigación se enmarca principalmente en predicciones STLTF y VSTLTF, debido a que el enfoque de aplicabilidad es a sistemas de gestión de la energía EMS en micro-redes.

4.3 Clasificación de los métodos de predicción de la demanda eléctrica a corto plazo

Hasta inicios del siglo veintiuno los modelos de predicción de demanda fueron clasificados en dos grupos [39]: uno los modelos de series de tiempo (invariantes), donde la carga es modelada en función de valores de observaciones pasadas, y el otro grupo los modelos causales, donde la carga es modelada en función de algunos factores exógenos, especialmente variables climáticas y de aspecto social.

En lo que se refiere a modelos de series de tiempo se encuentran los modelos de auto-regresión múltiple [40], modelos dinámicos lineales [41], modelos no lineales [42], modelos auto-regresivos de media móvil (ARMA Auto Regressive Moving Averagemo), modelos ARIMA [43] [44], métodos basados en filtro de Kalman [45] [46] [47], métodos de suavización exponencial [48].

Al segundo grupo de modelos corresponden modelos como: Modelos de series de tiempo Box and Jenkins [49], modelos ARMAX [50], regresiones no paramétricas [51], múltiple regresión lineal [52] [53], modelos estructurales, espacio de estado [54] etcétera. Los modelos causales más populares son los de regresión lineal y los modelos que descomponen la carga con dependencia de variables climáticas. Sin embargo, estos modelos son básicamente lineales y la serie de la demanda es claramente función no lineal de las variables exógenas.

A fines de los noventa es cuando se inician investigaciones del uso de inteligencia artificial para la predicción de demanda a corto plazo. Partiendo por el uso de sistemas expertos [55], de inferencia difusa [56] y modelos difuso-neuronal ANFIS [57], y con mayor interés los modelos con redes neuronales artificiales RNA. En la Figura 23 se muestra la clasificación más general de modelos de predicción de demanda antes del 2000.

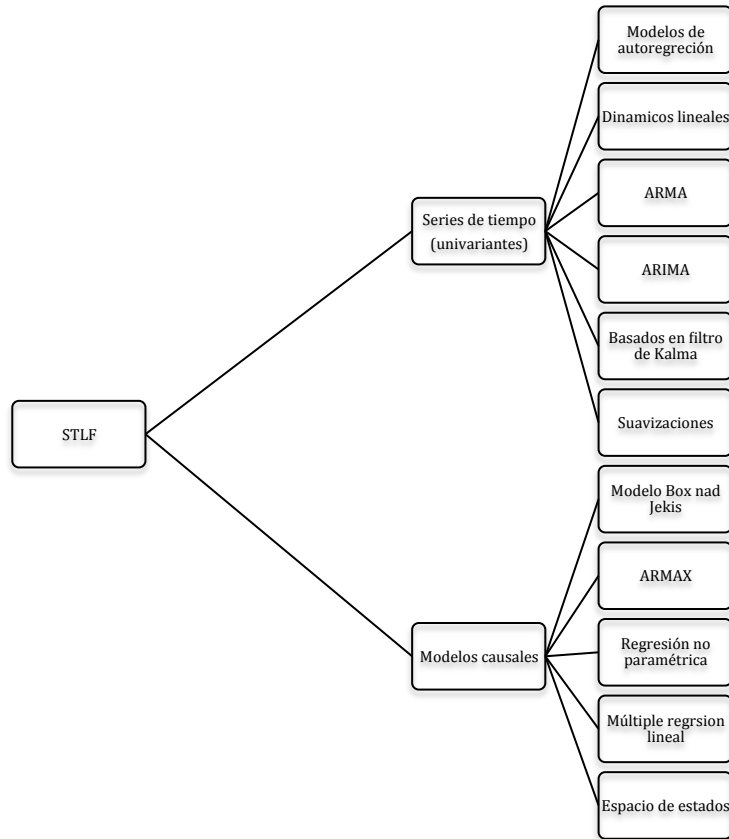


Figura 23 Clasificación de los predictores de demanda antes del 2000 [58]

Los métodos de predicción de la demanda eléctrica STLF a partir de la última década se han separado en grupos como: los de enfoques clásicos o métodos paramétricos, entre ellos se encuentran los de regresiones múltiples, de suavización exponencial [61], Box y Jenkins [61], filtro de Kalman y estimación de estados [67].

Por otro lado están los métodos de inteligencia artificial o no paramétricos como: sistemas expertos [55], redes neuronales y lógica difusa [58]. Por último los métodos híbridos que combinan varias técnicas para lograr la predicción de la demanda eléctrica [84]. En la Figura 24 se muestra una clasificación de los métodos de estimación a corto plazo, dentro de la última década. Dividiéndose principalmente en aquellos modelos clásicos, los modelos basados en inteligencia artificial, y los más recientes basados en modelos híbridos.

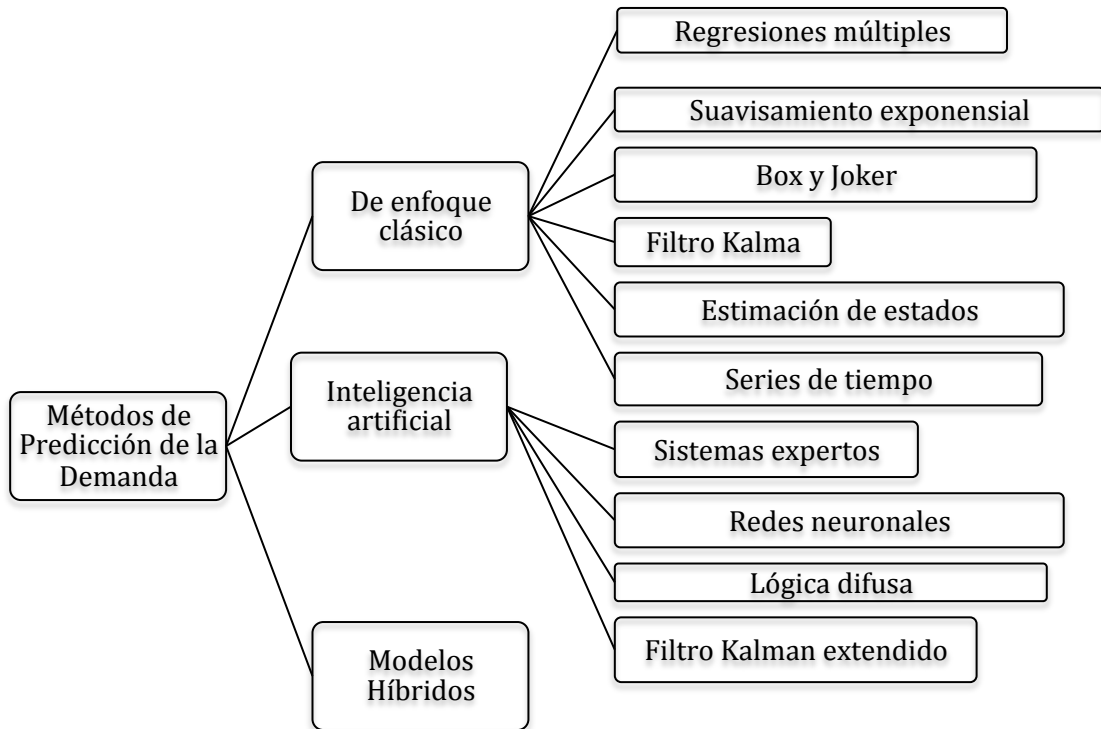


Figura 24 Métodos de estimación de la demanda eléctrica a corto plazo más recientes recogidos en la investigación [58]

Enfoques clásicos.- Se basan en métodos estadísticos. Estos modelos pueden no representar correctamente las complejas relaciones no lineales entre la carga y una serie de factores como los ritmos de tiempo diario y semanal, que puede provocar errores en la predicción de la demanda.

Métodos de inteligencia artificial.- Tienen la capacidad de dar un mejor rendimiento en el tratamiento de la no linealidad. El STLF es una área prometedora para redes neuronales artificiales (RNA), y muchas de las investigaciones se centran en este tema.

Métodos híbridos.- Son aquellos que combinan varias estrategias o a su vez se complementan con técnicas de pre-procesamiento de datos o generan variantes en sus algoritmos en etapas de optimización como: enjambre partícula, algoritmo genético, wavelets, análisis de componentes principales (PCA Principal Component Analysis), soporte de vectores de máquina (SVM Support Vector Machine).

Las investigaciones más recientes se enfocan principalmente en modelos híbridos [59], en su mayoría procesan las señales de entradas ya sea usando filtros o transformadas [80] [81], cada vez se consideran más entradas a los modelos principalmente de carácter climático, [74], además datos de demanda pasadas, normalmente separándolas por hora, y considerando días similares así se distingue los días normales de los fines de semana [66] [68]. En la mayoría de las propuestas los modelos utilizan como modelos base a las redes neuronales, que son combinadas con otras técnicas como difusas [77], además las redes

propuestas normalmente son recurrentes [76], o pueden utilizar funciones radiales [78], también pueden incluir modificaciones en el entrenamiento de las mismas al usar en lugar de mínimos cuadrados algoritmos genéticos [83]. Los trabajos cada vez buscan mejorar sus desempeños es por eso que al analizar sus resultados se comparan con otras metodologías. Para validar su superioridad, la forma de cuantificar el desempeño de las propuestas es principalmente y en su mayoría usando el error porcentual absoluto medio (MAPE Mean Absolute Percentage Error) [56], [39], [75].

Con los nuevos avances tecnológicos principalmente en el sector eléctrico, nuevos trabajos se han enfocado a estudiar a los autos eléctricos como una carga del sistema, cosa que en trabajos anteriores no fue contemplado, iniciando estudios en la predicción de la demanda eléctrica específicamente en cargas por autos eléctricos. Wu en su trabajo [85], plantea una metodología teórica de estimación de la energía eléctrica y el consumo de energía por el servicio en los vehículos eléctricos enchufables (PEVs Plug-in Electric Vehicles). Utilizando los patrones de viaje de vehículos ligeros en los EE.UU, bajo dos escenarios, el uno cuando la carga de los vehículos es en el hogar, y la otra denominada oportunista cuando el vehículo es cargado en cualquier lugar (casa, centro comercial, el trabajo, etcétera). Los autores aseguran que sin control de carga PEVs es casi seguro que aumentará el sistema de potencia, convirtiéndose en protagonista de carga máxima en los EE.UU. En la sección 4.3 se describen técnicas recientes de predicción de la demanda.

En el Anexo 1 se muestra una tabla que resume de forma cronológica las metodologías para predicción de la demanda eléctrica, que incluye esta investigación.

4.4 Técnicas de predicción usadas para estimar la demanda eléctrica a corto plazo

Del 2000 en adelante es cuando la predicción de la demanda a corto plazo tiene mayor interés, y en este rango es donde este trabajo de investigación enfoca su mayor atención, por su aplicación en la gestión de la micro-red.

4.4.1 Predicción de la demanda usando series de tiempo

El objetivo del análisis de una serie de tiempo es el conocimiento de su patrón de comportamiento, para así poder prever su evolución en el futuro cercano, suponiendo que las condiciones no variarán significativamente.

Una de las principales aplicaciones del estudio de las series de tiempo está relacionada a la predicción de los valores futuros de una variable. La mejor manera de explicar el comportamiento de una variable es el estudio de su tendencia a largo plazo, el problema que trae consigo es que una serie contiene una considerable cantidad de fluctuaciones aleatorias y cambios estacionales al corto plazo lo que hará difícil encontrar cierto comportamiento particular, por ejemplo la presencia de una tendencia [88].

Los métodos de predicción por series de tiempo se fundamentan en las técnicas de suavización y modelos de auto-regresión que consideran como entradas únicamente regresiones de la demanda [88].

En esta sección se analiza predicciones por suavización, mientras que las técnicas por auto-regresión se analizan de forma independiente más adelante.

Las técnicas más usadas para realizar la suavización son: el método de media o promedio móviles (usados

antes de esta década), suavización exponencial simple, suavización exponencial doble (método de Brown) y el método de suavización con tendencia y estacionalidad (método de Holt- Winters). De todos los métodos de predicción los métodos de Holt- Winters [60] son utilizados en trabajos actuales, las otras técnicas en la última década no son utilizadas.

Las técnicas de medias móviles o promedio de los datos del pasado, en trabajos actuales no son de interés. Sin embargo es una técnica de fácil implementación que puede ser usada como referencia para comparaciones con otros modelos, como en el trabajo de Tylor [61], que utilizando datos de diez países europeos, emplean esta técnica con dos variantes, la primera que es una versión estacional de caminos al azar. La predicción se construye simplemente como el valor observado para el período correspondiente de la semana anterior. La función de predicción se escribe como, $\hat{y}_t(k) = y_{t+k-s_2}$, donde y_t es la demanda en período t , y k es el tiempo de predicción ($k \leq s_2$). La segunda variante es el método de promedio simple de las observaciones correspondientes en cada una de las cuatro semanas anteriores. Para este método, la función de pronóstico es el modelado: $\hat{y}_t(k) = (y_{t+k-s_2} + y_{t+k-2s_2} + y_{t+k-3s_2} + y_{t+k-4s_2})/4$, como era de esperarse el error porcentual medio absoluto (MAPE Mean Absolute Percentage Error) al usar técnicas de medias móviles es superior a técnicas como: exponencial simple, AR periódico, ARMA estacional, técnicas basado en PCA, y método de suavización exponencial Holt-Winters, y un modelo suavizado exponencial de ciclo intradiario de doble estacionalidad. Bajo el criterio de considerar las estacionalidades de la serie de demanda eléctrica el autor propone, evaluar el método de suavización exponencial de Holt-Winters con una extensión de estacionalidad doble. El método ha sido adaptado para dar cabida a los dos ciclos estacionales de la serie de la demanda eléctrica. Un punto importante a destacar con respecto a este método es que, en contraste con los modelos ARIMA y la mayoría de los otros enfoques de la predicción de la demanda a corto plazo, no existe un modelo de especificaciones requerido.

Bajo la misma línea esta vez incorporando ciclos intradiarios analizan el modelo suavizado exponencial de ciclo intradiario de doble estacionalidad [61]. Una característica de la doble estacionalidad del método Holt-Winters es que asume el ciclo intradiario el mismo para todos los días de la semana, y que las actualizaciones del ciclo intradiario se realizan en la misma tasa por cada día de la semana. Una forma alternativa es la usada en este modelo que permite que el ciclo intradiario para los diferentes sea representado por diferentes componentes estacionales. Además, se permite que los componentes estacionales diferentes se actualizan con diferentes tasas por el uso de parámetros distintos suavizados. La implementación a la semana se divide en tres tipos: los días laborables, sábados y domingos. Los parámetros se estiman, reduciendo al mínimo la suma de cuadrado de un paso adelante en la muestra de los errores.

4.4.2 Predicción de la demanda usando modelos de regresión

Trabajos como el planteado por Cerda y Palma [62], utilizan modelos de regresión para predicción de la demanda eléctrica, como parte de una estrategia de control de demanda en base a generación distribuida. El modelo propuesto combina dos modelos basados en regresión, Modelo A (para predecir periodos de consumo alto) y modelo B (para predecir periodos de consumo bajo), que se combinan basados en una funciones de pertenencia, ambos modelos ocupan para su identificación dos etapas: la primera que consiste en la identificación de variables para esto utilizan método de regresión por paso, y la otra etapa la identificación de parámetros utilizan modelos ARMAX. Como su aplicación es en control de demanda se

pone atención principalmente en el horario del día donde se produce mayor demanda, en el día después (día A), y el día antes (día B).

En el modelo A se identifica datos después de la demanda máxima, considerando los datos de días anteriores. El modelo usado es el siguiente :

$$D_t^n = \alpha_1 D_{(t-1)}^n + \alpha_2 D_{(t-2)}^n + \beta_1 D_{(t)}^{n-1} + \beta_2 D_{(t-2)}^{n-1} + \beta_3 D_{(t-7)}^{n-1} + \beta_4 D_{(t-8)}^{n-1} + \beta_5 D_{(t-9)}^{n-1} + \beta_6 D_{(t-14)}^{n-1} + \beta_6 D_{(t-14)}^{n-1} + \delta_1 D_{(t)}^{n-2} + \delta_1 D_{(t)}^{n-2} + \delta_2 D_{(t-2)}^{n-2} + \delta_3 D_{(t-3)}^{n-2} + \delta_4 D_{(t-5)}^{n-2} + \delta_5 D_{(t-7)}^{n-2} + \delta_6 D_{(t-10)}^{n-2} + \delta_7 D_{(t-12)}^{n-2} + C_{Ec. 7}$$

El modelo B que en cambio es un modelo de datos demanda menores, es con el fin de poder estimar la demanda de menor magnitud, se utiliza los datos de demanda de una semana anterior a la demanda máxima (día B).

$$D_t^n = \alpha_1 D_{(t-1)}^n + \alpha_2 D_{(t-2)}^n + \alpha_3 D_{(t-55)}^n + \alpha_4 D_{(t-6)}^n + \alpha_5 D_{(t-11)}^n + \alpha_6 D_{(t-13)}^n + \beta_1 D_{(t)}^{n-1} + \beta_2 D_{(t-6)}^{n-1} + \beta_3 D_{(t-11)}^{n-1} + \beta_4 D_{(t-12)}^{n-1} + \delta_1 D_{(t-9)}^{n-2} + \delta_1 D_{(t-10)}^{n-2} + C_{Ec. 8}$$

Para la predicción total diaria, al perfil lo dividen en tres zonas, la zona de menor consumo y usa el modelo B, zona de transición de mínimo a máximo consumo utiliza un promedio entre los dos modelos, y la zona consumo punta, usa el modelo Ha, a cada zona le corresponde valores independientes de ponderación y con diferentes valores medios.

4.4.3 Predicción de la demanda usando modelos ARX

Los modelos de auto regresión con entradas exógenas (ARX Auto Regressive with Exogenous Input) y el uso de una base de conocimiento se plantea en la investigación realizada por Chen y Du [63] para la predicción de la demanda eléctrica a corto plazo. En este trabajo se plantea el uso de tres modelos ARX, combinados con una etapa de selección en función a una base de conocimiento, aplicada específicamente a la estación climática de invierno en Texas. En la Figura se muestra el proceso de predicción que se estructura de la siguiente forma. Primero se recolecta datos de mediciones pasadas de demanda, variables climáticas como temperatura, humedad y velocidad de viento. Segundo se analiza de los datos y en función de esto obtienen la base de conocimiento, determinando tres grupos de datos, los datos para días normales de invierno que corresponde al perfil más repetitivo de invierno, datos tipo I (muy frio en la mañana y por la tarde se va normalizando), datos tipo II (días en que la máxima demanda se produce únicamente en la noche después de terminar la jornada de trabajo). Este conocimiento les permite distinguir que se requiere tres modelos ARX uno para cada grupo de datos.

Como tercera etapa es la identificación de cada uno de los modelos ARX, de forma independiente. Se describen que las entradas a los modelos son: las cargas del pasado, y las predicciones de las variables climáticas.

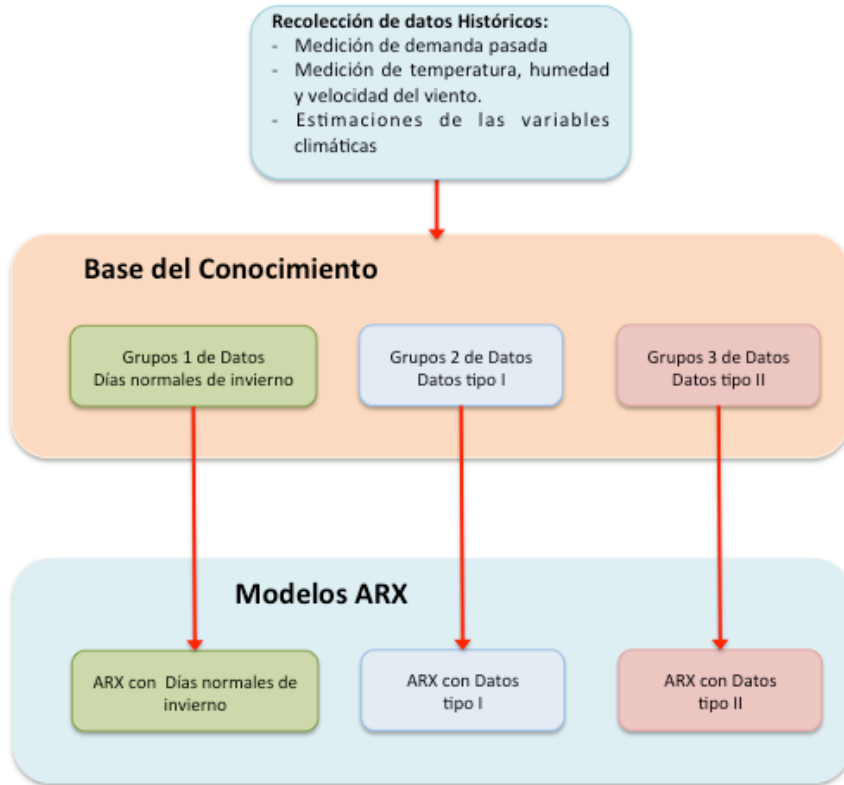


Figura 25 Procedimiento del desarrollo de predictor de demanda usando modelos ARX

El modelo funcional se describe en la Figura 26. Primero ingresan los datos pasados de demanda y las estimaciones de las variables climáticas. Luego se analiza si pertenece al grupo Tipo I, es decir perfil de días fríos en la mañana y por la tarde se va normalizando, si es así realiza la predicción usando el modelo ARX tipo I, caso contrario verifica si estos datos son de tipo II es decir cumplen con el perfil de días en que la máxima demanda se produce únicamente en la noche después de terminar la jornada de trabajo, de ser así realiza la predicción de la demanda usando el modelo ARX tipo II, caso contrario utiliza el modelo de predicción de demanda ARX para días normales de invierno.

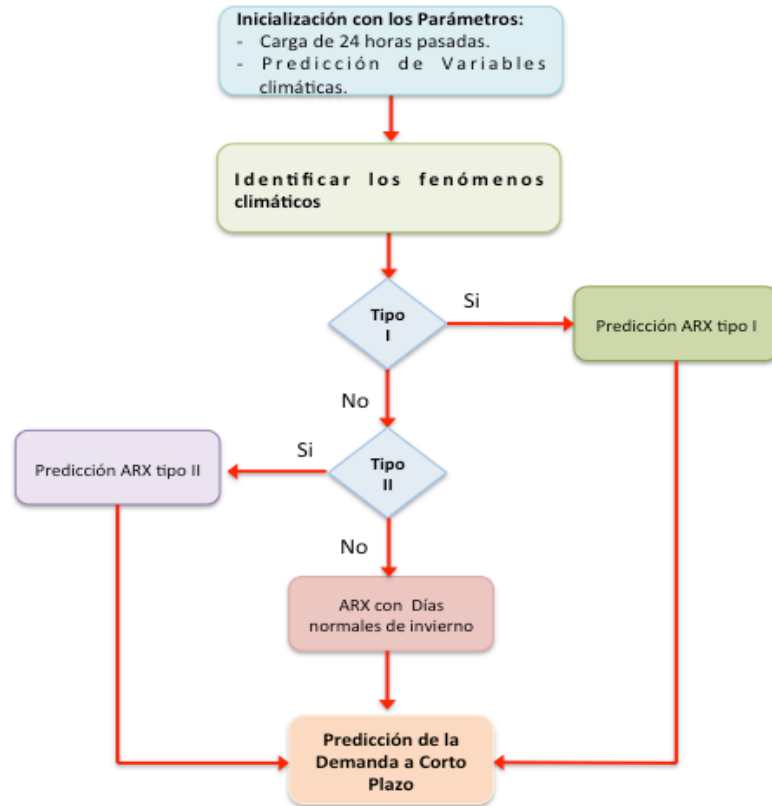


Figura 26 Aplicación del sistema de predicción de demanda usando modelos ARX

4.4.4 Predicción de la demanda usando modelos ARMA

Una de los modelos desarrollados por Taylor [61], se fundamenta en el uso de un modelo ARMA de doble estacionalidad, usando la metodología Box-Jenkins para identificar el modelo más adecuado, en función de datos de 20 semanas, para cada una de las series de carga. Se consideraron los polinomios de retardos de hasta tercer orden. Esta elección se realizó de manera arbitraria, pero es consistente con el pronóstico de carga de otros estudios, y fue apoyada por la experimentación con varias de las series. El modelo de selección es en base al Criterio Bayesiano Schwarz, con el requisito de que todos los parámetros fueron significativos (al nivel del 5%). Las variaciones que presenta la serie de tiempo como: valores máximo en el perfil diario de la demanda, y la similitud para los cinco días de la semana, y la diferencia para los fines de semana no puede ser capturado en el modelo ARMA anteriormente descrito. Es por eso que los autores plantean también una propuesta modificada usando modelos que pueden capturar estas características que son los modelos ARMA periódicos [61]. En estos modelos, los parámetros pueden cambiar con las estacionalidades. Sin embargo al comparar con otros modelos como: técnicas basado en (PCA Principal Component Analysis), y método de suavización exponencial Holt-Winters, éste resulto ser el menos eficiente, con un error MAPE superior a los anteriores.

Bajo el mismo enfoque del uso de modelos ARMA para la predicción de la demanda a corto plazo Jier y Rong, [64], proponen un modelo ARMA con un proceso non-Gaussing en la etapa de identificación. La identificación del modelo y estimación de parámetros son, por tanto empleados para llegar a un modelo

más representativo. Este enfoque fue probado y comparado con modelos como RNA y ARX simple, la evolución mostrada es mediante el cálculo de errores (real-predicción) por cada hora en un día, y se pudo observar que el error era menor en determinadas horas del día superando al ARMA convencional, de igual forma al comparar con las (RNA Redes Neuronales Artificiales) en determinados horarios podría decirse 10 horas indistintas del día lo supero. En la actualidad este método, se está extendiendo a un proyecto de utilidad que incluye las restricciones ambientales en el desarrollo de software.

4.4.5 Predicción de la demanda usando modelos ARIMA

Hay trabajos que han buscado mejorar las predicciones usando los modelos ARIMA como es el propuesto por Amjady [65] donde presentan un ARIMA modificado, que lo usan para predecir la demanda por hora y este misma técnica también la usan para la predicción de carga diaria máxima.

El modelo ARIMA modificado, incorpora al modelo ARIMA tradicional el conocimiento de la experiencia del operador humano a cargo, para lo cual realizaron estudios estadísticos de la demanda, incluyendo las cargas por hora y los máximos consumos en la carga diaria de la red eléctrica de Irán. El método modificado ARIMA combina la estimación de los operadores con la temperatura y los datos de carga, usando la estimación de los operadores como la predicción inicial. Luego se combina esta predicción inicial con datos de temperatura y de carga en una regresión de múltiples variables, para obtener una mejor predicción. Por esta razón, la exactitud del método modificado ARIMA es mejor que el ARIMA simple, ya que este último no tiene punto de partida.

Esta característica puede ser atractiva para los centros de control de las redes de potencia, ya que en muchos casos hay operadores expertos, que puede aumentar la eficiencia del método modificado ARIMA. La relación básica del ARIMA tradicional está definida por: $A_{(q)}y_{(t)} + \sum_{i=1}^n B_{i(q)}U_{i(t)} = e_{(t)}$ Ec. 9. Donde $y_{(t)}$ es la salida, $U_{i(t)}$ son las estradas al modelo ARIMA, $e_{(t)}$ el término del error o ruido, y n el número de entradas. El ARIMA modificado está determinado por: $A_{(q)}y_{(t)} + \sum_{i=1}^{n+1} B_{i(q)}U_{i(t)} = e_{(t)}$ Ec. 10, pero se varia el límite de la sumatoria por $n+1$, de donde $B_{n+1(q)} = b_{n+1}$ un polinomio de retardo de grado cero, y $U_{n+1(t)} = y_{estim(t)}$ donde $y_{estim(t)}$ es una estimación de la salida $y_{(t)}$, lo mismo ocurre para la predicción de la demanda máxima diaria. Sus resultados muestran mejoras al ARIMA tradicional principalmente en días festivos, y ante cambios a fines de semana, la métrica usada para cuantificar la comparación entre métodos es MAPE para el caso de predicción diaria y el error porcentual absoluto del pico de demanda (PAPE Peak Absolute Percentage Error), para la predicción de carga máxima diaria.

Murillo en su trabajo [66] presenta un pronóstico de demanda de energía eléctrica, utilizando la metodología ARIMA, los datos históricos son de la Empresa de Energía de Pereira-Colombia. La serie no es completamente aleatoria y se pueden describir como series de tiempo con una alta probabilidad de éxito en la modelación a través de esta metodología. Se dividen los datos en 24 series correspondientes a los promedios de consumo por cada hora del día; con ello se aíslan las perturbaciones causadas por el mes, la semana y la hora. Los datos originales no muestran estacionalidad, por tanto se aplica una diferenciación estacional y con ello se suaviza la serie logrando estacionalidad de tal forma que así se pueda ajustar un modelo ARIMA.

4.4.6 Predicción de la demanda usando filtro de Kalman

Hamadi y Solimn, [67] presentan un modelo difuso, para estimar la demanda eléctrica a corto plazo, el modelo utiliza ventana móvil de valores recientes de clima como datos pasados de carga y datos actuales

climáticos. Este modelo predice tanto la demanda como el error de predicción, para las 24 horas, el método de predicción se basa en espacio de estados con filtro Kalman, en conjunto con una base de reglas difusas. La técnica es usada recursivamente para estimar la demanda óptima, estimar los parámetros difusos para cada hora del día. Los valores centrales de los parámetros difusos representan el valor del pronóstico, mientras que los valores de propagación representan la cantidad de variación de la predicción. El valor de predicción de la propagación de demanda proporciona un aproximado de los valores extremos de la demanda. La eficacia de este enfoque es demostrado, con un porcentaje de error medio absoluto de 0,7%, de la predicción de demanda, y el error absoluto porcentual de desviación estándar de 0,9%. Los resultados mostraron que esta técnica supera a modelos de regresión lineal, regresión lineal múltiple, redes neuronales y sistema experto difuso.

4.4.7 Predicción de la demanda eléctrica usando razonamiento inductivo difuso (Fuzzy Inductive Reasoning FIR).

Una aplicación del uso de FIR con algoritmos evolutivos plantea Hinojosa y House. [68] Los autores proponen un método de estimación de carga a corto plazo (STLF), utilizando razonamiento inductivo difuso (FIR – Fuzzy Inductive Reasoning), además proponen un modelo de optimización que utiliza un algoritmo evolutivo basados en (SRA – Simulated Rebounding Algorithm) usado para elegir las entradas al modelo FIR, mejorando así los resultados de la predicción.

El modelo FIR aprende tanto de las relaciones pasadas y futuras de la carga y la temperatura. El uso de un método de optimización para determinar relaciones lineales y no lineales entre las variables, permite identificar el mejor grupo de entradas para lograr exactitud en la predicción. Las variables de entrada se actualizan cuando un nuevo patrón de carga ha ocurrido, o cuando los errores relativos son inaceptables. Con esta actualización se logra, que el proceso no sea estrictamente estacionario. En la Figura 27, se muestra la metodología FIR usada, y todas las etapas que incluye su desarrollo.

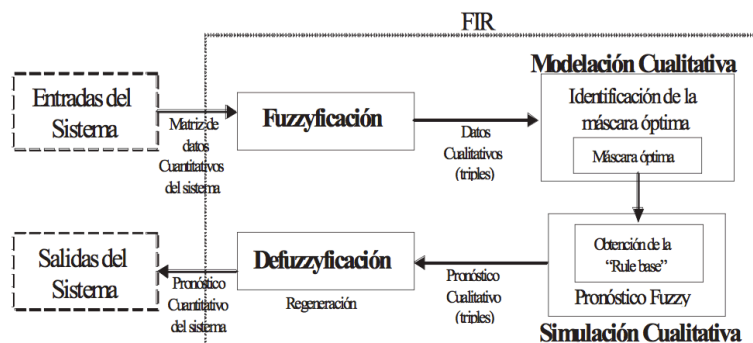


Figura 27 Razonamiento inductivo difuso [68]

Para la metodología FIR, primero se parte de la fusificación, que consiste en la selección del número de clases y sus límites, se puede hacer uso de información de expertos, a su vez utilizar histogramas o clasificadores. Los autores utilizan para STLF datos del mercado eléctrico ecuatoriano, considerando las dos regiones costa y sierra, debido a la diferencia climática existente entre ellas, utiliza las siguientes variables: *tipo de día* (variable fusificada en cuatro clases; lunes L1, otros días de la semana L2, sábado

SL, y domingo NL), *temperatura mínima para la sierra-Quito* que es fusificada en dos clases por rango de temperatura fresco (de 6 a 8 grados centígrados, y caliente (de 8 a 10 grados centígrados), *temperatura máxima para la sierra-Quito* de igual forma esta variable es fusificada en dos clases por rango de temperatura fresco (de 14 a 18 grados centígrados, y caliente (de 18 a 22 grados centígrados), *temperatura mínima para la costa- Guayaquil*, fusificada en dos clases por rango de temperatura fresco (de 18 a 20 grados centígrados, y caliente (de 20 a 22 grados centígrados), también la variable *temperatura máxima para la costa- Guayaquil*, es fusificada en dos clases fresco (de 25 a 27 grados centígrados), y caliente (de 27 a 35 grados centígrados), y como última variable usada para STLF es la de los históricos de carga pasadas, mediante fuzzy c-means, es como determinaron los cuatro grupos existentes de perfiles de acuerdo al día, la fusificación de los datos históricos se realizan de acuerdo al perfil del día que corresponde. Para el día lunes L1 cuatro clases que son: valle (la parte inferior del perfil con los valores más pequeños de demanda), resto (valores mayores que valle pero menores que los medios), medios (es cuando el perfil empieza a crecer considerablemente antes de llegar al consumo máximo), y la clase máxima demanda. Para los días L2 le corresponden las mismas clases, en cambio para el perfil del día sábado SL los grupos usados son únicamente valle, medio y demanda máxima, mientras que para el perfil del domingo NL le corresponde dos clases valle y demanda máxima.

Aplicando la fusificación a los datos históricos, el sistema multivariante es transformado en tres matrices llamadas: matriz de clase (discretización gruesa de los valores originales de la variable), matriz de pertenencia (denota el nivel de confianza expresado en el valor clase elegido para representar un particular valor cualitativo) y la matriz de flanco (el cual indica si el valor cuantitativo está a la derecha o a la izquierda del valor máximo de la función de membresía fuzzy asociada). El valor del flanco que es particular de la metodología FIR (no es comúnmente utilizado en la lógica fuzzy), es responsable de preservar el completo conocimiento del valor original cuantitativo.

Luego de la fusificación, la segunda etapa es la modelación cualitativa, que tiene como objetivo identificar los patrones (espaciales y temporales) en el tiempo, mediante la determinación del grupo de variables de entrada que mejor explican el comportamiento entrada-salida, esta relación es llamada máscara de correlación. La función de la máscara es seleccionar las m-entradas y la salida en cada matriz de clase, membresía y flanco, y transformar dichos valores en patrones estáticos de entrada-salida (estados del sistema). Desplazando la máscara de correlación sobre las matrices de clase, membresía y flanco, se obtienen distintos estados del sistema explicativos del comportamiento del mismo en el tiempo. El conjunto de estados del sistema es conocido como base de conocimiento. El problema de optimización para encontrar la máscara de correlación que tienen un mejor comportamiento comparadas con las máscaras encontradas por la metodología FIR tradicional, utilizando Algoritmos Evolutivos (Simulated Rebounding Algorithm) para determinar las entradas de la máscara de correlación como se explica más adelante.

Como paso siguiente de esta metodología es la Simulación Cualitativa (Qualitative Simulation). El objetivo de esta etapa es analizar y aprender patrones observados en la máscara de correlación con el fin de predecir el comportamiento futuro en base a los datos históricos. La predicción opera en dos etapas. En la primera etapa determinística: el patrón de entrada para el pronóstico es extraído de la matriz de valores clase por medio de la máscara y es comparado con todos los patrones análogos de la matriz de

comportamiento del sistema (datos históricos). Para todos aquellos patrones que coinciden con el patrón de entrada, se observan los valores clase de salida. La segunda etapa es estadística y se realiza la predicción del valor más probable de salida, a partir de las observaciones anteriores, mediante un promedio ponderado de los valores más próximos en la base de datos de entrenamiento. En esta etapa se utiliza la regla 4-NN (4 más cercanos vecinos).

Finalmente la etapa de Desfusificación, donde las predicciones de los valores de membrecía, flanco y código de clase de la salida pronosticada son convertidas a predicciones cuantitativas usando la operación inversa a la fusificación.

Esta propuesta que mezcla FIR y metodología de la SRA se aplica al sistema de energía de Ecuador como un ejemplo de aplicación, muestran los resultados y las comparaciones con otras metodologías de STLTF como: ARIMA, redes neuronales, ANFIS. Con esta metodología las variables cuantitativas (tiempo y carga) y variables cualitativas (día, temporada, etcétera) se han incorporado al modelo sin ningún formulación compleja. Se asegura que el modelo presentado es aplicable a cualquier problema de variables determinísticas y estocásticas que se considere.

4.4.8 Predicción de la demanda usando máquina de soporte vectorial para regresión (SVR Support Vector Regression)

Setiawan y Koprinske, [69] proponen un predictor de demanda eléctrica (VSTLF Very Short-Term Load Forecasting) usando SVR, para su realización hacen uso de WEKA un paquete computacional de la universidad de Waikoto, que cuenta con la herramienta SVR y otras más, que se basa en un algoritmo de optimización secuencial con los siguientes parámetros, que los fijaron de forma empírica: kernel polinomial $\epsilon=0,001$, $C=1$.

La modelación de un predictor de demanda con SVR, se describe en la Figura 28 y Figura 29. Inicia con la adquisición de datos históricos, posteriormente se realiza la selección de las variables importantes, haciendo análisis para determinar patrones, en este caso se distingue que entre semana se mantiene un patrón mientras que los fines de semana se produce otro, además determinan la existencia de diferencias estacionales, observando que las cargas para la primavera, el verano y el otoño son similares, mientras que la carga para el invierno es diferente y mayor. Sin embargo, se ha demostrado que el clima (temperatura) no influye en la exactitud de VSTLF, ya que cambia lentamente en una ventana de previsión de cinco minutos de tiempo.

Seguidamente determinan las características o regresiones asignadas a las variables de entrada, para su efecto realiza la técnica de prueba y error. Una vez determinadas las características. Utilizan el paquete computacional WEKA, específicamente SVR como datos necesarios de este paquete se requiere también kernel polinomial $\epsilon=0,001$, y $C=1$, obteniendo la predicción, para ser comparados con: regresores lineales LR (Linear Regression), mínimos cuadrados LMS (Least means squares), y red neuronal entrenada con backpropagation BPNN (Backpropagation Neural Network). SVR supero a los algoritmos de predicción BPNN, pero en este trabajo nunca describen la estructura de la red cuyas entradas no necesariamente tendrían que ser iguales a SVM, para que sea la estructura óptima. Sin embargo los modelos más simples, tales como LR y LNS producen resultados de similares exactitud y fueron más rápidos de entrenar que SVR.

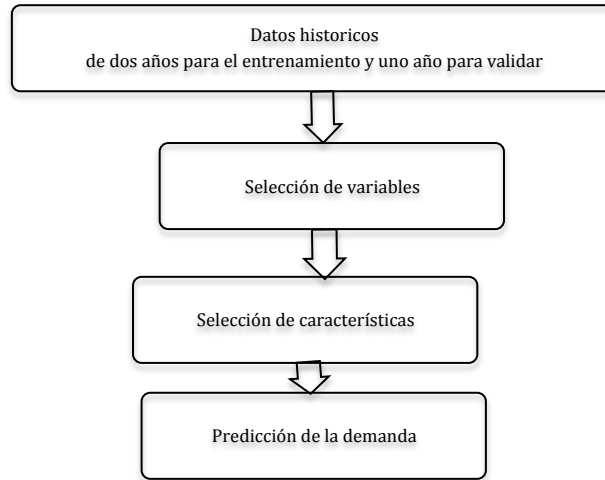


Figura 28 Modelamiento de VSTLF, usando SVR, incluido en el paquete computacional WEKA




Figura 29 Aspectos a considerar para la selección de variables

Un año después en el 2010, Ehab et al.[70], presentan una nueva propuesta de estimación de demanda eléctrica, denominada regresión de vector soporte ponderado localmente LWSVR (Locally Weighted Support Vector Regression), que combina regresión de vector soporte o máquina de vector soporte con regresión, SVR (Support Vector Regression) y regresión ponderado local LWR (Locally Weighted Regression), la propuesta consiste en la modificación de la función de riesgo del algoritmo SVR, con LWR utilizando la distancia de Mahalanobis para optimizar el ancho de banda de ponderación de funciones.

Se fusiona SVR con regresión ponderada a nivel local (LWR), que es un tipo de aprendizaje local ponderado. LWR forma un modelo local alrededor de un punto de interés por lo que solo entrena datos que son más cercanos al punto, que serán usados en cada consulta, en lugar de utilizar todos los datos de entrenamiento.

LWR es un método para estimación de una superficie de regresión multivariante mediante suavizado: la variable de respuesta se suaviza de forma dinámica, en función de las variables de predicción [71]. LWR consiste en desarrollar un modelo local a un conjunto de vecinos más cercanos.

En el modelo propuesto, al involucrar estas dos técnicas han dividido en cuatro etapas principales a su propuesta. La primera etapa, en la que se reconstruye la serie de tiempo multivariante mediante la incorporación de dimensión y la constante de retardo. La segunda etapa se encuentra el vector vecino más

cercano K , para la consulta actual, usando distancia Euclidiana, y calcula el parámetro de ancho de banda (h) y la función de ponderación de cada punto del vecindario. Entonces se calcula la función de riesgo modificada de SVR. La tercera fase entrena el SVR con modificación de la función de riesgo utilizando sólo los K vecinos más cercanos. La cuarta etapa se evalúa el modelo utilizando el vector de la consulta como la entrada a estimar la salida del proceso. Al evaluar el modelo concluyen que este método LWSVR supera a LWR y SVR independientes.

4.4.9 Predicción de la demanda eléctrica usando redes neuronales artificiales (RNA)

La predicción de la demanda eléctrica a corto plazo usando redes neuronales tiene interés a partir de los noventa su investigación se masifica a partir del año 2000, de ahí en adelante son varias las investigaciones asociadas a este tema, los primeros estudios son principalmente sobre el uso de las redes neuronales en este campo, en donde algunos autores se mostraban escépticos principalmente por los problemas de sobre-parametrización, y la selección acertada de los datos de entrada a entrenar de forma supervisada [39], problemas que pueden ser superados con una buena identificación neuronal. Es la técnica más utilizada y probada hasta los últimos tiempos para predicción de demanda.

Entre los trabajos asociados al tema se tiene el realizado por Chen yPing [72], que se enfocaron en la aplicación de estrategias de predicción de demanda usando redes neuronales considerando como entradas a diferencia de otros trabajos un índice de calor equivalente a la temperatura que percibe el ser humano (HI- HeatIndex), específicamente para el sistema eléctrico de Taiwán, que cuenta con características climáticas diferentes por zonas. Para esto se propone un predictor de demanda a corto plazo en multi-regiones de Taiwán. Aseguran que debido a las distintas características climáticas de Taiwán, es difícil obtener resultados satisfactorios de estimación tratando toda la isla como una sola región. Además, factores climáticos, tales como temperatura, humedad relativa, y el índice de calor (HI) puede afectar también a las cargas. En este trabajo mejoran la estimación a corto plazo, que previamente propuso en una de sus investigaciones el Centro de Sistemas de Energía de la Universidad Texas en Arlington [73], donde la predicción de carga lo hacen usando redes neuronales, interviene la temperatura como parámetro de entrada a la red neuronal.

Como se puede ver en la Figura 30, esta nueva propuesta introduce como variantes primero la separación de la estimaciones por cuatro diferentes regiones de Taiwán, y aplicando un índice de calor (HI) como un parámetro de entrada.

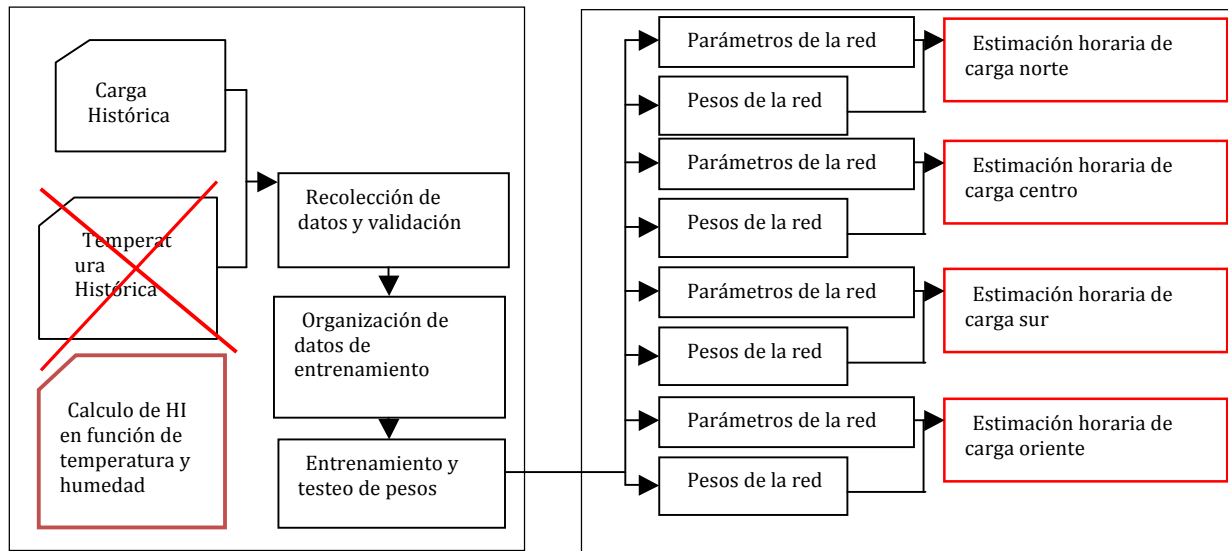


Figura 30 Predicción de la demanda eléctrica a corto plazo usando como entrada el índice de calor calculado HI (Heat Index)

Este trabajo parte de la adquisición de datos y su análisis, clasificados por cuatro regiones, una región norte, centro, sur y oriente. Estables correlación entre variable y calculan HI que es un parámetro del clima que combina la temperatura y la humedad relativa para determinar una temperatura aparente. En otras palabras, el efecto de la humedad relativa aumentará el HI, lo que distorsiona en los humanos la percepción de calor. Este ajuste de temperatura puede verse en la gente al utilizar el aire acondicionado, especialmente en verano.

La fórmula que describe HI es la siguiente:

$$HI = C_0 + C_1T + C_2R + C_3TR + C_4T^2 + C_5R^2 + C_6T^2 + C_7TR^2 + C_8T^2R^2 \text{ Ec. 11}$$

Donde C_0 a C_8 , son valores constantes previamente determinados, las unidades de HI con grados Celsius, T temperatura ambiente medida en grados Celsius, R la humedad relativa. Posteriormente realizan las estimaciones por regiones y finalmente se obtiene resultados numéricos que demuestran una mejora positiva en la predicción de carga del sistema Taipower mediante la aplicación del modelo por multi-regiones y el uso de HI como parámetro de entrada de RNA. Los autores muestran una comparación de tres modelos: el primero un modelo que lo tenían operando basado en una red neuronal que tiene como entradas demanda pasadas, y temperatura, el segundo modelo con la metodología propuesta usando redes neuronales teniendo como entradas la demanda pasada y el HI calculado, además incorporar un tercer modelo que tiene como entrada temperatura, HI y demandas pasadas. Al comparar estos tres modelos se verifica que el modelo propuesto mejora el comportamiento.

Methaprayoon y Lee [74], abordan el diseño sistemático de un predictor de demanda a corto plazo multi-etapa basado en redes neuronales, modelo que actualmente se encuentra implementado.

La propuesta de los autores se observa en la **Figura 30**, donde se distinguen dos bloques.

El primer bloque en la parte inferior, es donde se realiza propiamente la predicción utilizando redes neuronales a este modelo lo llaman (ANNSTLF Artificial Neural Network Short Term Load Forecasting), utiliza como entradas los datos correctamente validados de las estimaciones de la temperatura, en tiempo real, además de la demanda y temperaturas medidas y proporcionadas por el sistema de adquisición de datos y en función de estas se obtiene la predicción de la demanda a corto plazo.

El segundo bloque colocado en la parte superior, produce la predicción de temperatura, para lo cual desarrollan un servidor donde están monitoreando y almacenando predicciones de temperatura de cinco centros meteorológicos, para después con el uso de redes neuronales obtener la predicción de la temperatura final, que es utilizada como entrada del modelo estimador.

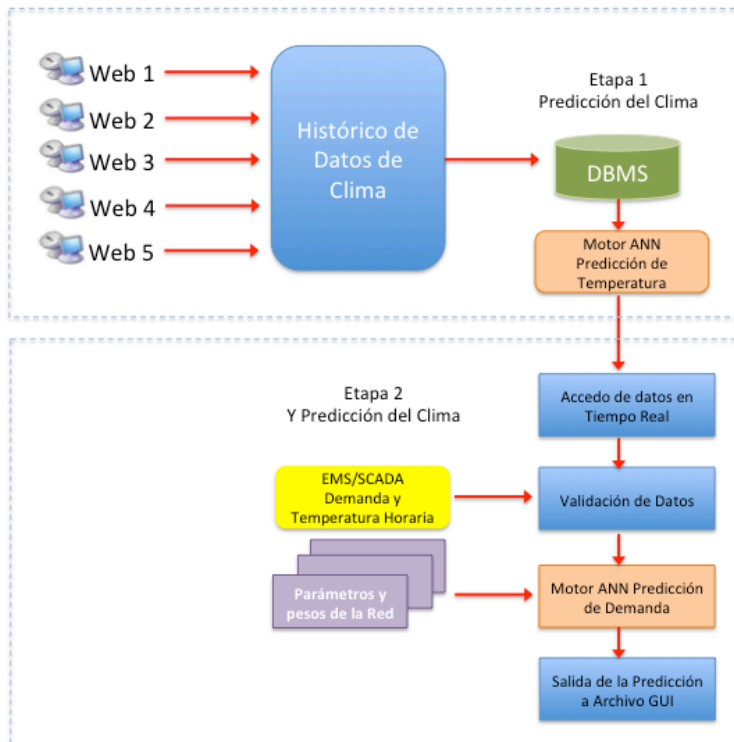


Figura 31 Estructura del modelo ANNSTLF para predicción de demanda usando como entradas predicciones de temperatura

El pronosticador (ANNSTLF) en su diseño tiene como primer paso, extraer las características de carga, tales como la periodicidad y las tendencias mediante el análisis de los registros anteriores de carga. Una observación importante del análisis de la carga anterior es la distinción de patrones de carga diferentes en la semana. Separando al modelo en cuatro grupos se construye un modelo individual para predecir la carga para cada grupo: grupo 1 [D1] correspondiente a lunes, grupo 2 [D2] correspondiente a: martes, miércoles y jueves, el grupo 3 [D3] correspondiente a viernes y finalmente el grupo 4 [D4] para sábado y domingo.

Posteriormente realizan la selección de las variables de entrada. En la predicción de carga a corto plazo, las variables importantes son el tiempo, las variables meteorológicas, y demandas históricas. Para determinar las variables de importancia utilizan análisis de sensibilidad expuesto en el trabajo desarrollado por Castellanos y Ríos [75]. Otro enfoque para identificar las variables de entrada potenciales es por análisis de correlación estadística. En este enfoque, el índice de coeficiente de correlación lineal se calcula entre cada entrada y la salida. ANNSTLF se entrena de manera supervisada. En este trabajo se aplica un modelo de tres capas de redes neuronales feedforward. La función tangente hiperbólica se utiliza en la capa oculta y la función lineal se utiliza en la capa de salida. El número de neuronas en la capa de entrada y la capa de salida, se fija por el número de entrada y el número de salidas, respectivamente, mientras que el número de neuronas en la capa oculta, lo hacen primero partiendo de un determinado número de neuronas calculado por la siguiente ecuación:

$$\mathit{neuronas}_{ocultas} = \sqrt{\mathit{Entradas} * \mathit{Salidas}} \text{Ec. 12}$$

Después el número de neuronas ocultas se aumenta una a una, se entrena la red, se obtiene las predicciones y se calcula el error de pronóstico registrándolos para la comparación.

Esta herramienta de predicción es muy dependiente de los errores de estimación de la temperatura, por eso deciden usar una red neuronal con datos de cinco servidores web, y cinco modelos extras asumiendo que se toma como entrada la predicción de temperatura de cada servidor web independientemente.

La mayoría de investigaciones usan redes neuronales considerando como entradas datos de consumo pasados y bajo este criterio Senjyu y Takara, [76] aseguran que ante cambios de estaciones climáticas una red neuronal no es lo suficientemente poderosa para detectar estos cambios siendo insuficientes estas entradas y proponen mejorar estos problema con el uso de selección de días similares, incorporando con ello incluso reducción de tiempos de entrenamiento. La red neuronal propuesta utiliza los datos de la desviación de la potencia de carga y los datos de desviación de la temperatura, como datos de aprendizaje.

Por lo tanto, es posible reducir la estructura de red neuronal y el tiempo de aprendizaje. Además, este método de predicción de carga mediante RNA, es con aprendizaje en línea. Los datos realimentados, y el error de predicción se utilizan como datos de aprendizaje para el aprendizaje en línea. Las entradas son nueve, veinte neuronas en la capa oculta, y una neurona en la capa de salida. En esta propuesta la predicción de carga es obtenida por la suma de una corrección al dato del día similar, donde la corrección es obtenida por una red neuronal, como se aprecia en la Figura 32, la red neuronal usa desviación de la potencia de la carga y la desviación de temperatura como datos de entrenamiento. Además este método de predicción de carga usa la red neuronal con aprendizaje en línea. Entonces los datos realimentados y predicción del error son usados como datos para el entrenamiento en línea. Las variables la red propuesta son: la predicción de carga \hat{L}_{t+1} , datos de días similares un promedio de cinco días similares seleccionados \bar{L} , carga actual L_{t+1} , desviación en temperatura entre la predicción y un día similar ΔT^{t-k} , corrección por predicción de carga ΔC^{t-k} , desviación de potencia entre la estimación diaria y un día similar ΔL^{t-k} ($k=0, 1, 2$).

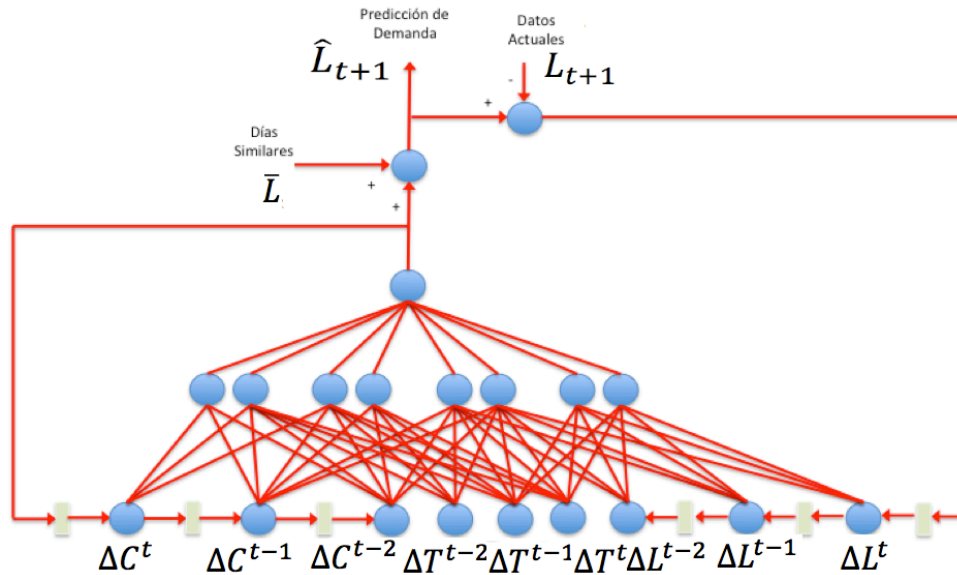


Figura 32 Modelo de red neuronal implementado para predicción de demanda eléctrica [76].

Para la verificación de esta propuesta se comparan con cuatro casos. El primero considera predicción de la demanda usando un modelo de regresión simple, el segundo caso usando únicamente datos de días similares, el tercer caso usa una red neuronal con aprendizaje en línea, entonces únicamente los días similares son usados en el aprendizaje para entrenar en línea, el cuarto caso considera una red neuronal con aprendizaje en línea, con datos de retro-propagación y el error de predicción usados como datos de aprendizaje en línea. Al comparar los modelos mediante MAPE (Mean Absolute Percentage Error) evaluación hecha durante un año, para el caso uno es de 13.8 %, caso dos de 1.28%, caso tres 1.23% y para el caso cuatro de su propuesta es de 1.18%

Trabajo más recientes se enfocan la Estimación de la demanda eléctrica usando redes neuronales con (FBR Función de Base Radial). Uno de los trabajos que utilizan este tipo de redes neuronales es el presentado por Yuan y Zhou, [78] en el que proponen como estrategia de predicción de carga a corto plazo en micro-redes, el uso de redes basadas en función de base radial (RBF).

El diseño de entradas y salidas está definido como se muestra en la Figura 33. Donde las entradas del sistema son 24 bloques equivalentes a cada hora y cada bloques formado por un grupo de factores que son: temperatura seca, humedad, rocío, humedad relativa, y variable binaria que representa el día al que pertenece. Estas variables son definidas para proporcionar confort a los usuarios.

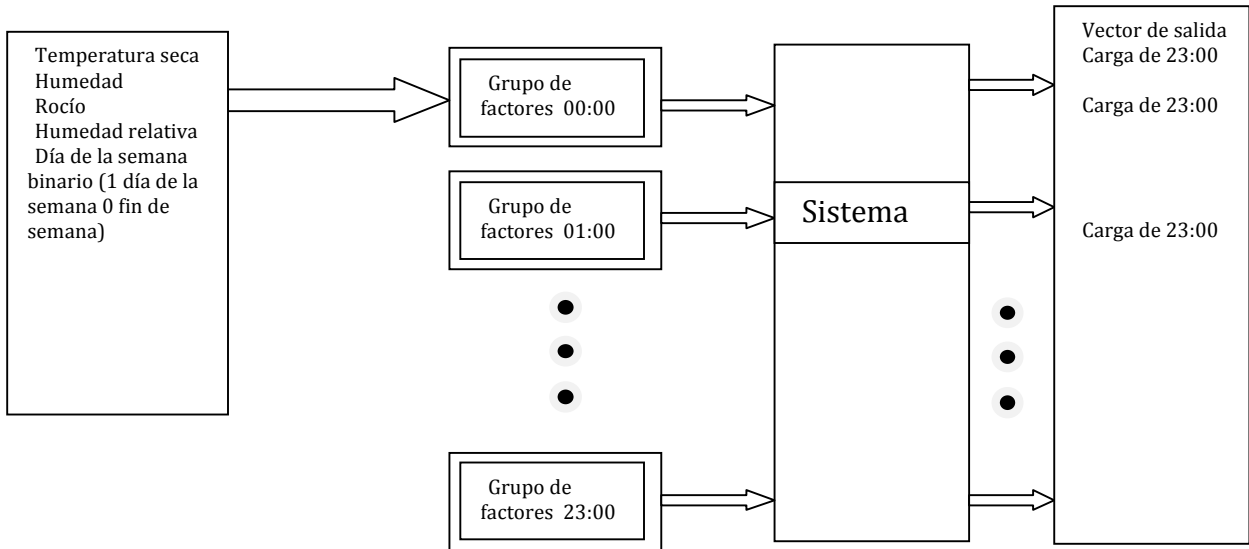


Figura 33 Predicción de la demanda eléctrica usando redes tipo RBF [78]

Realizan varias ejecuciones con distintos valores de bias y número de neuronas y deducen que a mayor valor de bias menor MSE, y que a mayor bias menos neuronas se requieren. En este trabajo se muestra una aplicación práctica del uso de redes RBF en estimación de carga.

Hay trabajos que han incorporado a la predicción con redes neuronales RBF etapas extras como ANFIS, es el caso de [79] donde Yun y Quan utilizan redes neuronales RBF y ANFIS para la predicción de carga a corto plazo con enfoque en el precio de la energía en tiempo real.

El diagrama de su propuesta se observa en la Figura. El primer modelo RBF, usa una red RBF para predecir la carga en el día de predicción, modelo en el que no interviene la variable del precio de la electricidad. A continuación, el modelo ANFIS en base de los cambios recientes en el precio en tiempo real, ajusta los resultados de la predicción de carga obtenidos por la red RBF. Esta integración del sistema mejorará la predicción.

Las variable de entrada de ANFIS es la predicción por la red neuronal RBF (x_1) y el cambio de precio de la electricidad (x_2), el precio esta definido por:

$$x_2 = 100 * (d_1 - d_2) / d_1 \text{ Ec. 13}$$

Donde d_1 es el precio de la electricidad previsto en un día (punto), y d_2 es el precio de un punto anterior en el mismo día (punto anterior). Las variables de entrada se dividen en muy bajo, bajo, normal, alto, muy alto, y la salida de ANFIS que representa el cambio de la carga en muy baja, baja, sin cambios, alta y muy alta. El número total de reglas difusas es de 25. Este modelo es aplicado cuando se requiere considerar el precio de energía en la estimación de la demanda y su influencia en la demanda. Prueban con un ejemplo y demuestra que el método propuesto es flexible y práctico para STLF bajo la condición de los precios en tiempo real.

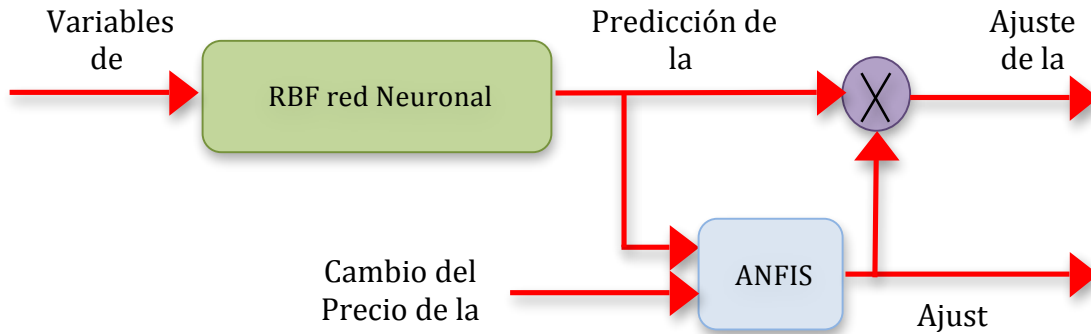


Figura 34 Predicción de la demanda usando RBF con ajuste ANFIS [79]

4.4.11 Predicción de la demanda eléctrica usando modelos híbridos

En la literatura especializada se asegura que incorporar transformadas Wavelet a los datos de entrada de modelos de predicción mejora los resultados. En la propuesta de Shekhar y Singh [80], plantean que al incorporar una etapa de pre-procesamiento de datos, usando descomposición de Wavelet como estradas a cualquier modelo de estimación como: series de tiempo, red neuronal RBF, pronosticador neuro-fuzzy, regresión lineal múltiple (MLR), red neuronal con propagación hacia delante (FFNN), redes con funciones radiales, red neural inferencia difusa (FINN), etcétera, se logra menores errores de estimación, comparado con tomar los datos históricos de forma natural. La Figura 35, muestra la propuesta planteada, en donde plantean una etapa de pre-procesamiento de datos, previo al modelo de estimación.

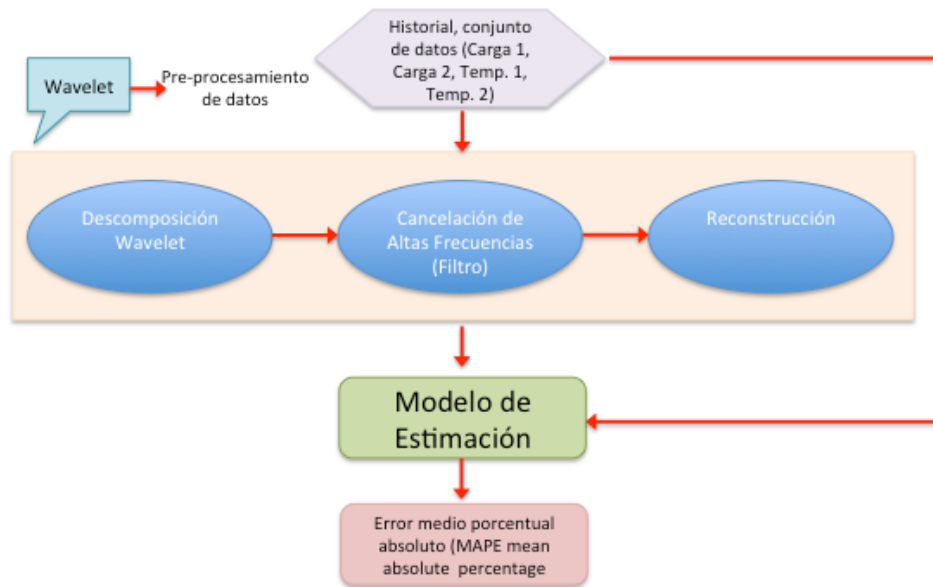


Figura 35 Predicción de la demanda eléctrica usando transformada wavelet [80]

El proceso de la descomposición wavelet propuesto consiste en primero descomponer la carga histórica y variables climáticas, en una parte aproximada asociadas a baja frecuencias y varias partes de detalle asociados a las componentes de altas frecuencias a través de la transformada wavelet. El histórico de datos es suavizado por la eliminación de los componentes de alta frecuencia y a su vez alimentan a los

modelos para la predicción. El análisis de los resultados obtenidos indica la superioridad del método propuesto basado en wavelets comparados con métodos de estimación que no consideran wavelet y demuestra que el uso de los datos pre-procesados a través de técnica wavelet no sólo mejora el rendimiento de los modelos de pronóstico, al mismo tiempo toma menos tiempo los entrenamientos. La simplicidad del enfoque permite aplicar el método a distintos modelos de predicción, tanto tradicionales como no tradicionales, de una manera directa.

Bajo el mismo criterio, Chen, Luh, y Guan, [81] proponen un sistema de estimación de corto plazo denominado base de días Similares, Wavelet y Redes Neuronales, (SIWNN-Similar Day-Based Wavelet Neural Network), que combina la selección del día similar, la descomposición wavelet, y redes neuronales para predecir la carga de mañana. La idea clave es seleccionar el día de carga similar como carga de entrada basados en el análisis de correlación y aplicar descomposición wavelet para capturar las características de la carga en baja y frecuencias altas, y luego usar redes neuronales independientes para predecir los dos componentes de la carga de mañana. En la Figura 36, se muestra la descripción gráfica de esta metodología.

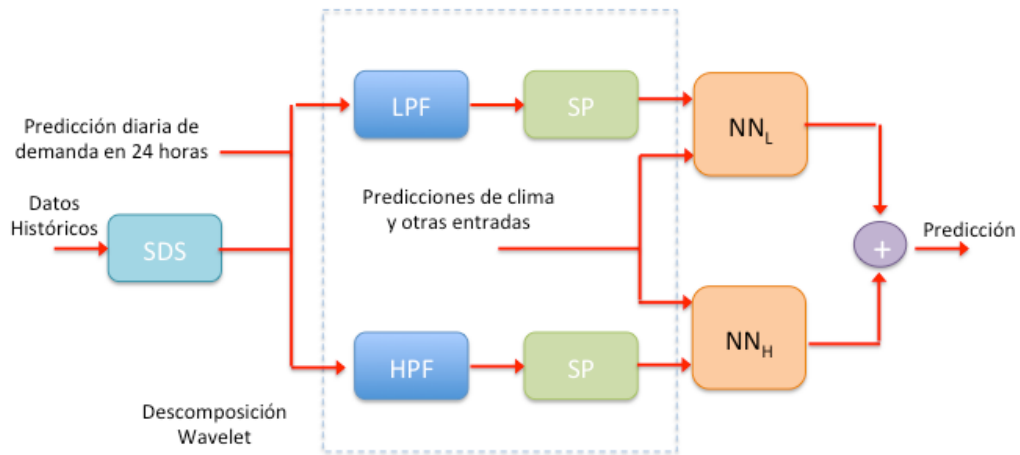


Figura 36 Estimación a corto plazo en base de días Similares, Wavelet y Redes Neuronales, (SIWNN-Similar Day-Based Wavelet Neural Network)

La propuesta se compone de cuatro etapas, la primera que la denomina índice de días laborables y clima. Aquí se identifican los factores que afectan a la carga considerando los de mayor impacto como; el índice del día de la semana que es un factor importante que difiere un día de otro, además el tiempo es muy importante en definir un cierto perfil, y el clima. La información meteorológica utilizada en SIWNN incluye la temperatura de sensación térmica, humedad, velocidad del viento, la nubosidad y la precipitación, además realizan el cálculo de la temperatura fría en función de la temperatura del aire y la velocidad del viento, que permite identificar la estación de invierno.

La segunda etapa que es la selección de entradas similares de carga SDS. De todo un historial de carga que suelen ser utilizadas como entradas para la red neuronal para la predicción, una pregunta principal es como seleccionar correctamente el día y para predecir el día D (mañana), lo común es usar como entradas las más recientes es decir la carga de ayer (D-2) y la carga de una semana atrás con un índice de día es decir correspondiente al día similar (D-7), el coeficiente de correlación entre la señal predicha D y del día anterior (D-2) es menor que el coeficiente de correlación entre el estimado y un día similar, lo que les

lleva a establecer que con día de carga similar tiene un poder de predicción mayor que el de carga más reciente. El criterio de selección de días similares es en base a ISO de nueva Inglaterra [82], y la selección del día requiere tener similar índice del día de la semana y similar clima del día de la mañana.

La tercera etapa consiste en la descomposición de la carga de entrada en alta y baja frecuencia, con wavelets de Daubechies tipo ortogonales. En SIWNN, wavelet Daubechies 4 (DB4) es usado para descomponer la carga de entrada en un componente de baja frecuencia y un componente de alta frecuencia.

En la última etapa se usan dos redes neuronales perceptrón de tres capas, se utilizan por separado para la componente de baja frecuencia y la componente de alta frecuencia. Para la red de baja frecuencia, las entradas son seleccionados en base a experiencia y son; el índice de la semana, temperatura del aire frío procesado, velocidad del viento, la nubosidad y baja frecuencia de cargas en días similares, componente de bajas frecuencias de cargas similares, componentes de baja frecuencia de predicción de carga de 24 horas. Para la red de alta frecuencia, son las mismas entradas pero en alta frecuencia. Como se observa en la Figura 37.



Figura 37 Entradas de las redes neuronales del modelo de predicción de corto plazo en base de días similares, wavelet y redes neuronales (SIWNN - Similar Day-Based Wavelet Neuronal Network) [82]

La componente de alta frecuencia de la carga del día similar es una de las principales entradas en vista de su buena correlación con la alta frecuencia de la carga de mañana.

Las dos redes neuronales se entrenan primero utilizando datos históricos, con los criterios de selección similares a base de un día. Los resultados muestran mejoras al usar cargas de días similares. Al combinar selección de días similares, descomposición wavelet y redes neuronales para predecir la demanda del siguiente día, obteniendo errores MAPE (error porcentual absoluto medio) de hasta 0.14 incluso en días festivos.

Hay trabajos que aparte de incorporar wavelets, redes neuronales, incluyen PSO (Particles Swarm Optimization), como algoritmo de optimización. La optimización por enjambre de partículas (Particle Swarm Optimization, PSO) es un algoritmo de optimización estocástico basado en poblaciones, inspirado en el comportamiento de bandadas de aves, cardúmenes, enjambres de abejas, o incluso en el

comportamiento social humano. Como algoritmo, las principales fortalezas de PSO son su rápida convergencia.

El trabajo desarrollado por Bashir y Hawary [83], utiliza la unión de tres técnicas que contribuyen en la estimación a corto plazo, fusionando primero el manejo de los datos de entrada al modelo, estableciendo su caracterización por medio de transformadas de wavelet. Segundo utilizan PSO (Particles Swarm Optimization) en la etapa de entrenamiento del modelo de la red neuronal, para ajustar los pesos y sesgos, cambiando en backpropagation la técnica de optimización y lo denominaron WNNs-PSO. El proceso de aprendizaje consiste en minimizar como función objetivo el error que representa la diferencia entre la salida de la red y la meta correspondiente. Los resultados del modelo fueron comparados con los de modelos tradicionales de redes neuronales con backpropagation y ofrece una precisión de pronóstico más alta, destacando la importancia de tener un buen modelo neuronal. En la Figura 38, se muestra la estructura general de su propuesta.



Figura 38 Predicción de la demanda eléctrica usando Wavelet y PSO en el entrenamiento de la red neuronal WNNs-PSO

Técnicamente, los datos de carga se transforman en los coeficientes de baja y alta. Los coeficientes bajos son una versión aproximada que se asocia con el filtro paso bajo mientras que el segundo es una versión más detallada que se asocia con un filtro de pasa altos. La selección de la wavelet base o madre tiene un efecto significativo sobre los resultados obtenidos. Seleccionan la wave Daubechies DB2, que es elegido sobre otras familias wavelet Daubechies para descomponer los datos en dos niveles a fin de reflejar los factores de incertidumbre sobre las características de la carga diaria. La característica de ortogonalidad de DB2, permite la reconstrucción de la señal original a partir de los coeficientes de transformación sin perder la información.

La topología de la red implementada es como se muestra en la Tabla, los modelos de redes neuronales se entrenan con 3 a 12 neuronas como datos de entrada, mientras que 8 y 4 neuronas en las capas ocultas primero y segundo, respectivamente, y una neurona en la capa de salida, el número óptimo de neuronas en la capa oculta se han determinado sobre la base de "prueba y error".

Tabla 4 Estructura de la red usada para el modelo de estimación que usa wavelet PSO y redes neuronales

Capa	Tipo de datos	Número de neuronas
Entrada	Carga actual y de dos horas anteriores	3
Entrada	Temperatura actual y de dos horas anteriores	3
Entrada	Velocidad del viento actual y dos horas anteriores	3
Entrada	Humedad actual y dos horas anteriores	3
Ocultas		2 ocultas una de 8 neuronas y la otra de 4 activadas por Tansig
Salida	Carga no linealizada	1 Activada por Purelin

El entrenamiento lo hacen utilizando PSO con aprendizaje supervisado, donde las ponderaciones se actualizan con el fin de reducir la función de error cada vez que la salida de la red no coincide con los valores deseados. La función que usan es "TRAINPSO" de las redes neuronales WNNs-PSO de trabajos anteriores. Utilizan un tamaño de enjambre igual a 20,25 y 30 partículas, siendo el óptimo 20, la gama del espacio de búsqueda es entre [-25 25], los valores de aceleración ($n1=n2=2$). Los resultados de este trabajo muestran los beneficios de incorporar estas técnicas y determina que al usar PSO el tiempo de entrenamiento es menor, y los errores al incluir wavelets es menor.

Huang y Yang [84], plantean las primeras propuestas de métodos híbrido que utilizan transformadas wavelet, que utiliza una red neuronal basado en wavelets para STLF, en la actualidad la mayoría de trabajos se enfocan en modelos híbridos.

En el trabajo [85] presentan dos redes neuronales híbridas, derivadas de redes neuro-difusas (FNN Fuzzy neuronal Network). El primer modelo híbrido denominado red wavelet neuro-difusa (WFNN Wavelet Fuzzy Neural Network), usa funciones wavelet fuzzificadas como entradas para FNN. La otra red híbrida es una red neuro-difusa que emplea la integral Choquet como la salida de FNN. El aprendizaje de FNCI es simplificado por el uso de q-measure y la velocidad de convergencia de los parámetros crece, usa un aprendizaje reforzado. El modelo FNN, es un modelo de reglas Takagi-Sugeno. El número de reglas encontradas por una curva fuzzy correspondiente a cada entrada-salida para contar el número total de puntos más altos y bajos en la curva. Los resultados de estos modelos son comparados con ANFIS, los resultados muestran que el modelo de mejor predicción es WFNN.

Taylor y McSharry [61] en su trabajo utilizan un modelo basado en PCA para las comparaciones con otro modelos. El método tiene como objetivo capturar la variación intradiaria en la demanda eléctrica, y puede ser visto como un desarrollo por separado para cada uno de los períodos del día. El método explota la similitud entre observaciones intradiarias con el fin de reducir el número de modelos a considerar.

Teniendo en cuenta que este enfoque podría ampliarse fácilmente para un caso multivariante. Se arreglan las observaciones como una matriz Y de ($nd \times s1$), donde nd es el número de días en la muestra. Cada columna contiene observaciones por un período máximo intradiario en particular. PCA se aplica a las

columnas de Y que son a su vez componentes columnas de una nueva matriz. Para cada componente, se construye un modelo de regresión con los días de la semana y tendencia cuadrática. Los modelos se utilizan para ofrecer un pronóstico del día siguiente para cada componente. El método centra la atención únicamente en los componentes principales. La validación cruzada se utiliza para optimizar parámetros: el número de componentes principales y la longitud del periodo de entrenamiento usado en PCA. Finalmente, con esta especificación del modelo que ahora incluye el término de corrección de error anterior, la validación cruzada se utiliza para optimizar el número de componentes principales y la longitud del periodo de formación utilizada en el PCA.

4.4.12 Predicción de la demanda eléctrica específicamente para micro-redes

Predecir la demanda eléctrica en micro-redes tiene mayor complejidad que predecir en sistemas tradicionales, esto principalmente porque a cambios mínimos de carga en una micro-red se ven reflejados en variaciones significativas, mientras que en los sistemas convencionales no tiene similar impacto porque puede ser compensado por otros cambios de carga en paralelo o porque los cambios mínimos no son percibidos. En menor cantidad hay trabajos aplicados a estimaciones a corto plazo en micro-redes. Amjady y Keynia [86], describen, una nueva estrategia de predicción de dos niveles como se observa en la Figura 39, para STLF en micro-redes. La estrategia propuesta se compone de dos niveles. Un nivel superior que incluye una técnica de búsqueda estocástica propuesta para la optimización del desempeño de todo el predictor denominado algoritmo de evolución diferencial (EDE-Enhanced Differential Evolution). EDE es un variante de evolución diferencial (DE-Diferencial Evolution), para optimizar el rendimiento del predictor.

Mientras que en el nivel bajo cuenta con dos etapas. La primera etapa es una técnica de selección de características. La segunda etapa es un motor de pronóstico (incluyendo redes neuronales y algoritmos evolutivos. Este trabajo es basado en una investigación previa realizada por los mismos autores [87], donde realizan un modelo de predicción CNEA que está compuesto de una estimación de cascada donde cada estimación está formado por una red neuronal y algoritmos evolutivos usados para predecir el precio en el mercado eléctrico, en este nuevo trabajo [86], utilizan CNEA que corresponde al nivel inferior de la propuesta Figura 40 (Método de selección de características más el motor híbrido de predicción híbrido por usar red neuronal y EA).

En la Figura 40, se muestra la estructura y proponen como primer paso para STLF identificar los factores que afectan la carga de la señal. Una variedad de candidatas de entradas puede ser considerada, tales como los valores de carga pasada, pronóstico y valores de factores climáticos como (temperatura, humedad, etcétera) y los indicadores de calendario. Sin embargo, no es posible aplicar todos estos entradas al motor de pronóstico. Además, pueden incluir ineficaces características de entrada que complican el proceso de formación del motor de predicción y degradar su rendimiento. Así, el conjunto de entradas candidatas debe ser lo primero en precisarse.

Se identifica el algoritmo de evolución diferencial (EDE-Enhanced Differential Evolution), que es una versión mejorada del DE, para la optimización del desempeño del estimador. El operador de recombinación del DE lo han modificado en EDE de acuerdo a las características del problema de optimización. La población EDE evoluciona con mayor rapidez que la población DE. La propuesta EDE

conserva la característica importante de DE, es decir, los procesos por separado de cada gen de las soluciones candidatas en base a la propuesta del operador de recombinación, lo que aumenta la diversidad del proceso de búsqueda y la capacidad de exploración de EDE evitando caer en mínimos locales. Al mismo tiempo, EDE puede tener convergencia a mayor tasa de DE. Otra ventaja de la EDE es que su recombinación es de forma automática, genera el vector de ruta y no requiere seleccionar el valor de RR (RR indica la tasa de recombinación del DE). Para EDE, el umbral RR se sustituye por FF, que es adaptable cambiando para cada individuo en cada iteración mejorando la convergencia de EDE.

Dentro del mismo modelo de estimación Figura 40, en el nivel inferior como primera etapa se encuentra el método de selección de características. Se sabe que un conjunto de entradas candidatas, pueden ser grandes y no puede ser utilizado directamente para cualquier modelo. Además, hay presencia de candidatas irrelevantes y redundantes. En esta propuesta [87] utilizan una técnica que anteriormente la desarrollaron los autores, es una técnica de selección de características no lineales, que se basa en información mutua usando el conceptos de entropía. La técnica no lineal evalúa información mutua de cada candidato de entrada con la función objetivo y clasifica los candidatos de acuerdo a su valor de información. En esta técnica, se utiliza una aproximación de MI basado en la distribución binomial, que puede ser computada por una cantidad razonable de datos históricos, eliminando funciones redundantes.

En el mismo bloque inferior y como última etapa está el motor de estimación híbrida. El motor de estimación híbrida considerado es el usado en un trabajo anterior [87] utilizado para la estimación del precio diario en un mercado eléctrico en base al uso de redes neuronales y algoritmos genéticos. En la Figura 40, se muestra la estructura general, se compone de una red neuronal (NN) y de algoritmos evolutivos (EA). La parte NN usa perceptrón multicapa (MLP) y aprendizaje Leven-berg-Marquardt (LM), que es un mecanismo eficiente para predicción. EA se usa en las búsquedas en torno a la solución final del algoritmo de aprendizaje en varias direcciones tanto como sea posible para encontrar la mejor solución.

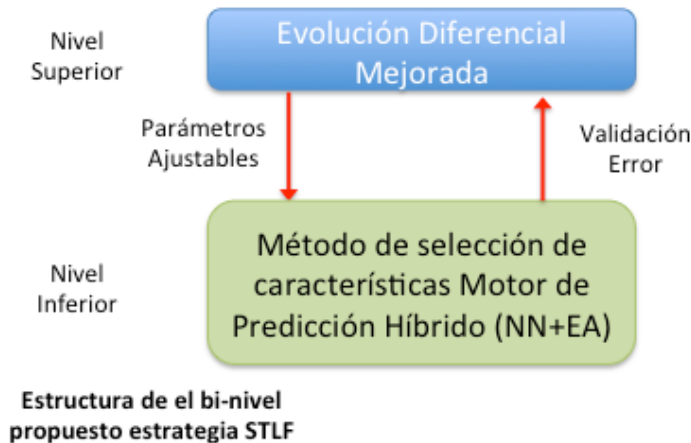
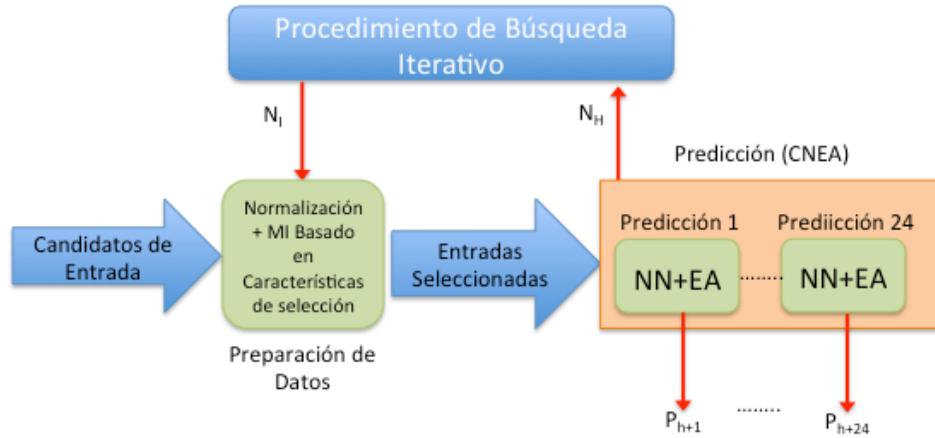


Figura 39 Estructura de la estrategia SLTF de dos niveles



Estructura de la estrategia de predicción propuesta

Figura 40 Estructura de la estrategia de predicción usando Redes neuronales mas algoritmos evolutivos EA.

La eficacia de la estrategia de predicción propuesta aplicada a micro-redes, se evalúa por los datos de la vida real de un campus universitario en Canadá que representa la micro-red, usan como unidad cuantificadora de comparación entre modelos el error medio semanal (Weekly Mean Error – WME) y la varianza, en donde muestran que esta nueva propuesta tiene menores errores comparados con ARIMA, ARIMA + Wevelet, Redes neuronales con algoritmos genéticos.

4.5 Criterios de evaluación en modelos de predicción de demanda eléctrica

Son varios los indicadores que se han usado para la evaluación de los modelos de predicción de demanda eléctrica a corto plazo. A continuación se definen las técnicas de evaluación cuantitativa más usadas para validar estos tipos de modelos:

El más básico que es la determinación del error de predicción, que es la diferencia entre el valor real y el valor predicho, definido por la siguiente ecuación:

$$e(t) = y(t) - \hat{y}(t) \text{Ec. 14}$$

Donde $e(t)$ representa el error de predicción para el instante t , y el valor verdadero de la variable, y \hat{y} el valor predicho para esa variable en el instante t .

Otro indicador usado es el error medio, ME (Mean Error), definido como el valor medio del error de predicción. Donde N es el número de muestras evaluadas.

$$ME = \frac{1}{N} \sum_{t=1}^N y(t) - \hat{y}(t) \text{Ec. 15}$$

Los indicadores estadísticos más usuales para evaluar el funcionamiento de un modelo de predicción son el error absoluto medio MAE, y la raíz del error cuadrático medio, RMSE. El indicador MAE se calcula:

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \text{Ec. 16}$$

El indicador RMSE se calcula, como la raíz del error medio cuadrático (raíz del valor medio del cuadrado del error). El indicador RMSE tiene las mismas unidades que la serie temporal que predecimos: por ejemplo, en la predicción de la demanda eléctrica es [W], se calcula según:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \text{Ec. 17}$$

Existen otros criterios o indicadores de error, como pueden ser el coeficiente de correlación, la desviación estándar del error, el criterio de información de Akaike, criterio de información Bayesiano de Schwarz, etcétera, de ellos el más común es la desviación estándar usado en este análisis.

El criterio más utilizado en esta investigación es MAPE [34]. Se calcula mediante la siguiente ecuación, donde y_i es el valor real y \hat{y}_i el valor predicho

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \text{Ec. 18}$$

El KPI [34] es un indicador del mejor rendimiento, que puede ser usado para comparar el rendimiento del MAPE, para esto se requiere calcular primero el MPE llamado ingenuo que se calcula de la siguiente forma:

$$MAPE_{ing} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_{i-1} - y_i}{y_i} \right| \text{Ec. 19}$$

Donde y_{i-1} es demanda real anterior, y y_i la demanda real actual, y N numero de muestras evaluadas. El KPI se calcula según la siguiente ecuación:

$$KPI = \frac{MAPE_{ing} - MAPE}{MAPE_{ing}} \text{Ec. 20}$$

El KPI aceptable puede ser del 20%.

4.6 Discusión

En este capítulo se efectuó un estado de arte de la mayoría de desarrollos respecto a la predicción de demanda eléctrica a corto plazo, obteniendo de su análisis una propuesta de predicción orientada principalmente a sistemas no tradicionales sino a sistemas más pequeños como micro-redes.

Del análisis de los distintos trabajos enfocados en la predicción de la demanda eléctrica a corto plazo se estableció que en la actualidad los métodos de regresión lineal y suavización de series de tiempo son menos usados, pero fueron los modelos pioneros en predicción de demanda eléctrica a corto plazo.

La predicción de demanda a corto plazo refleja sus primeros estudios a fines de los setenta, pero en los noventa fue de gran interés, y del 2000 en adelante se han enfocado en desarrollos más sofisticados, introduciendo inteligencia computacional. En estos últimos años se enfocan mucho en los sistemas híbridos y mezclan desde pre-procesamiento a las señales de entrada, hasta combinación de técnicas tradicionales con otras más sofisticadas.

En la mayoría de propuestas planteadas para la predicción de la demanda eléctrica a corto plazo, se utilizan redes neuronales, o en base a esta técnica surgen modificaciones y múltiples modelos híbridos, considerándose desde fines de los noventa la técnica más utilizada de predicción de control de demanda y sus resultados en la mayoría de estudios validan su buen funcionamiento esto principalmente por la característica de tratar las no linealidades.

Muchos trabajos optan como etapa previa a la predicción de la demanda realizar pre-procesamiento de las señales de entrada, mejorando las predicciones, la mayoría de trabajos utilizan principalmente transformadas Wavelet, o reducciones de características como PCA o ICA.

Hacer una buena selección de las variables de entrada de los modelos de predicción tiene importancia significativa, inicialmente se consideraba como entradas, únicamente la demanda pasada, después se incorporaron modelos que consideran también variables climáticas pasadas, más tarde a parte de estas variables también se considera predicciones de variables climáticas, y trabajos más recientes también incluyen índices que representan confort de los usuarios. Un aspecto que muchas de las investigaciones consideran son los días similares, la mayoría de casos introduce en sus modelos como entradas datos de días similares pasados, con eso incorporan la variabilidad de perfil diario entre los distintos días de la semana y también usan temperaturas de días pasados y futuros para incorporar las estaciones climáticas, una variable también importante es el tiempo es decir la fecha, y hora.

La predicción de la demanda eléctrica principalmente donde se tiene distintos climas en un mismo espacio territorial, o climas por regiones es conveniente analizar las predicciones por zonas que cuentan con característica climáticas similares, ya que en muchos estudios han demostrado que las variables climáticas son influyentes en la predicción principalmente cuando hay presencia de estaciones climáticas bien marcadas.

Algunos trabajos prefieren tratar a la demanda eléctrica diaria como 24 series de tiempo una por cada hora, esto principalmente para considerar que la demanda cambia en el tiempo durante un día.

Actualmente los trabajos tienen como principal objetivo disminuir los errores de predicción de demanda utilizando técnicas innovadoras. En los primeros trabajos planteados el error MAPE es de 15%, los nuevos trabajos manejan valores de 1.3 %, y cada vez buscan disminuir este valor así sea en proporciones pequeñas. Ante nuevos cambios y desarrollos investigativos en el sistema eléctrico surge el interés por las estrategias de predicción de demandas eléctrica aplicadas a micro-redes, considerando que la demanda total del sistema tiene diferente reacción ante un incremento o decremento de carga, que los sistemas convencionales. La predicción de la demanda en micro-redes tiene mucho interés y principalmente aplicabilidad es así que muchas de las propuestas son implementadas y se están ejecutando actualmente, conllevando a seguir perfeccionando técnicas de predicción.

La forma de evolución cuantitativa de la mayoría de modelos es utilizando el error absoluto promedio de predicción promedio MAPE.

CAPÍTULO 5

CONSTRUCCIÓN DEL PERFIL DE DEMANDA EN COMUNIDADES

5.1 Introducción

La obtención del consumo mensual eléctrico de una casa puede resultar fácil, basta con revisar la planilla mensual, pero esto no definen el perfil mensual ni el perfil diario de la demanda eléctrica, para poder obtener perfiles diarios de los hogares se requiere de medidores inteligentes que realicen registros en períodos cortos y dispongan de memoria de almacenamiento.

En algunas zonas se cuentan con medidores que registran datos por periodos cortos en los alimentadores primarios de las subestaciones de las empresas de distribución, que pueden mostrar un perfil de demanda de una determinada zona, útiles para futuras estimaciones de demanda, pero estos no son suficientes cuando se requiere definir perfiles diarios por casa, este aspecto tiene mayor importancia en proyectos de gestión de la demanda.

Los perfiles de demanda eléctrica son diferentes entre zonas rurales y zonas urbanas, por distintas condiciones y formas de vida. Los habitantes de zonas rurales siguen dependiendo de los combustibles tradicionales o de sistemas de abastecimiento de energía costosos e ineficientes, para satisfacer su demanda energética, que en muchos casos es limitada por horarios.

Algunos gobiernos están desarrollando proyectos de energización rural, en comunidades que disponen de energía limitada por horarios, abastecidas por unidades de generación caras, en la mayoría de los casos desaprovechando los recursos naturales propios de las zonas. Debido a las características geográficas de las comunidades aisladas, impiden la conexión con la red de distribución, impidiendo ser dotados de energía, buscando formas de abastecimiento autónomo con unidades de generación costosas, por lo que se ven limitadas a contar con suministro eléctrico por ciertas horas. Los proyectos de energización buscan aparte de beneficiar a comunidades de un servicio básico ininterrumpido, aprovechar los recursos con la inserción de energías renovables y con ellos los beneficios que esto implica.

* ESUSCON (Energía Sustentable Córdor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Frente a proyectos de este tipo surge la interrogante de cómo reaccionará la comunidad frente a la disponibilidad de energía las veinticuatro horas del día, y principalmente cual será el nuevo perfil de demanda de la comunidad. Sabiendo de antemano que por el hecho de no disponer de energía o de disponerla en tiempo limitado no se tiene mediciones que puedan servir de referencia para poder hacer una estimación futura de demanda, por lo que se busca otro tipo información disponible como información socio-económica obtenidas de encuestas que junto con una metodología adecuada se pueda generar un perfil de demanda futuro considerando que los usuarios cuentan con energía ininterrumpida.

Las razones más importantes de la construcción de perfiles de demanda para comunidades que disponen de energía por periodos limitados de tiempo o que no disponen de ella, es que permitirá obtener un perfil de demanda que se aproxime al que se tendría en caso de que la comunidad cuente con energía permanente, y en base a este perfil de demanda y los recursos disponibles realizar un dimensionamiento de las unidades de generación, para realizar propuestas, diseño y desarrollo de proyectos que buscan dotar de buenos sistemas de energía a estas zonas.

Para determinar la demanda energética de las comunidades rurales, se llevan a cabo estudios socio-económico con el objetivo de conocer con más detalle los requisitos energéticos de la localidad. El estudio socioeconómico se centra en las características sociales, laborales, organizacionales, culturales y económicas de cada comunidad. Este estudio, es llevado a cabo con una metodología concreta proporcionando información para determinar cuál es la demanda energética actual de cada comunidad y, además, proporciona información sobre el posible crecimiento que ésta puede sufrir en el futuro.

Este capítulo contiene: primero un método propuesto para la generación de perfiles de demanda en comunidades aisladas, con sus descripciones, segundo se realiza el estudio de caso aplicando la propuesta a una localidad del norte de Chile (Huatacondo) y finalmente se analizan los resultados obtenidos, de donde se realiza un análisis del capítulo.

5.2 Método propuesto para la construcción del perfil de demanda en comunidades.

Partiendo de la premisa que casi todos los desarrollos relacionados a la demanda eléctrica, usan datos históricos de demanda con suministro de energía las veinticuatro horas del día, y sumado a esto el comportamiento distinto del uso de energía entre zonas urbanas y rurales, es una tarea complicada suponer el perfil futuro de demanda en una comunidad que originalmente cuenta con energía por horarios limitados, y obtener un perfil, considerando que cuentan de energía sin interrupciones, y con escasas de mediciones.

Se sabe de antemano que los perfiles de comunidades podrán ir variando dependiendo de cuantas casas tiene cierta localidad, cuantos habitantes, que tipo de habitantes, sus hábitos y actividades. Pequeñas variaciones de consumo pueden reflejarse como perturbación importantes en el perfil total de demanda eléctrica de la comunidad.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

En esta sección se propone un método para generar perfiles diarios de demanda eléctrica en comunidades aisladas, tanto en un día normal así como en días festivos donde el número de habitantes se incrementa.

En la Figura se muestra la secuencia del método propuesta para la generación de perfiles de demanda, la descripción específica de cada etapa se la realiza más adelante, los cuatro primeros elementos corresponden al módulo de obtención de entradas, que incluye el obtener información general de la comunidad por medio de encuestas y visita a terreno, luego se obtiene la información individual por medio de encuestas realizadas a cada casa de la comunidad, al igual que la adquisición de mediciones en terreno, toda esta información requiere ser pre-procesada. Luego de tener ya los datos de entrada se realiza una etapa de clasificación con las encuestas individuales y se determina tipos de hogares existentes en la comunidad, para lo cual se utiliza mapas auto-organizados de Kohonen (SOM), como técnica de clasificación, de esto se obtiene: varias clases, los elementos de cada clase, y las características que le diferencian a cada clase. Con las características de la clase, se pasa al módulo de búsqueda que tiene la función de encontrar un perfil de demanda dentro de la base de datos que represente a cada clase, el caso de no encontrar un grupo que tenga similares características se usa un perfil específico para estos casos, al sumar estos perfiles se obtiene el perfil residencial de las casa encuestas. Además se determina el número de casas que no fueron encuestas y a su vez la demanda de las casas no encuestadas, de igual forma el módulo de generación de demanda de alumbrado público, y el módulo de centros educativos. Seguido se obtiene la demanda eléctrica par la comunidad, además de la demanda eléctrica al considerar días festivos.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

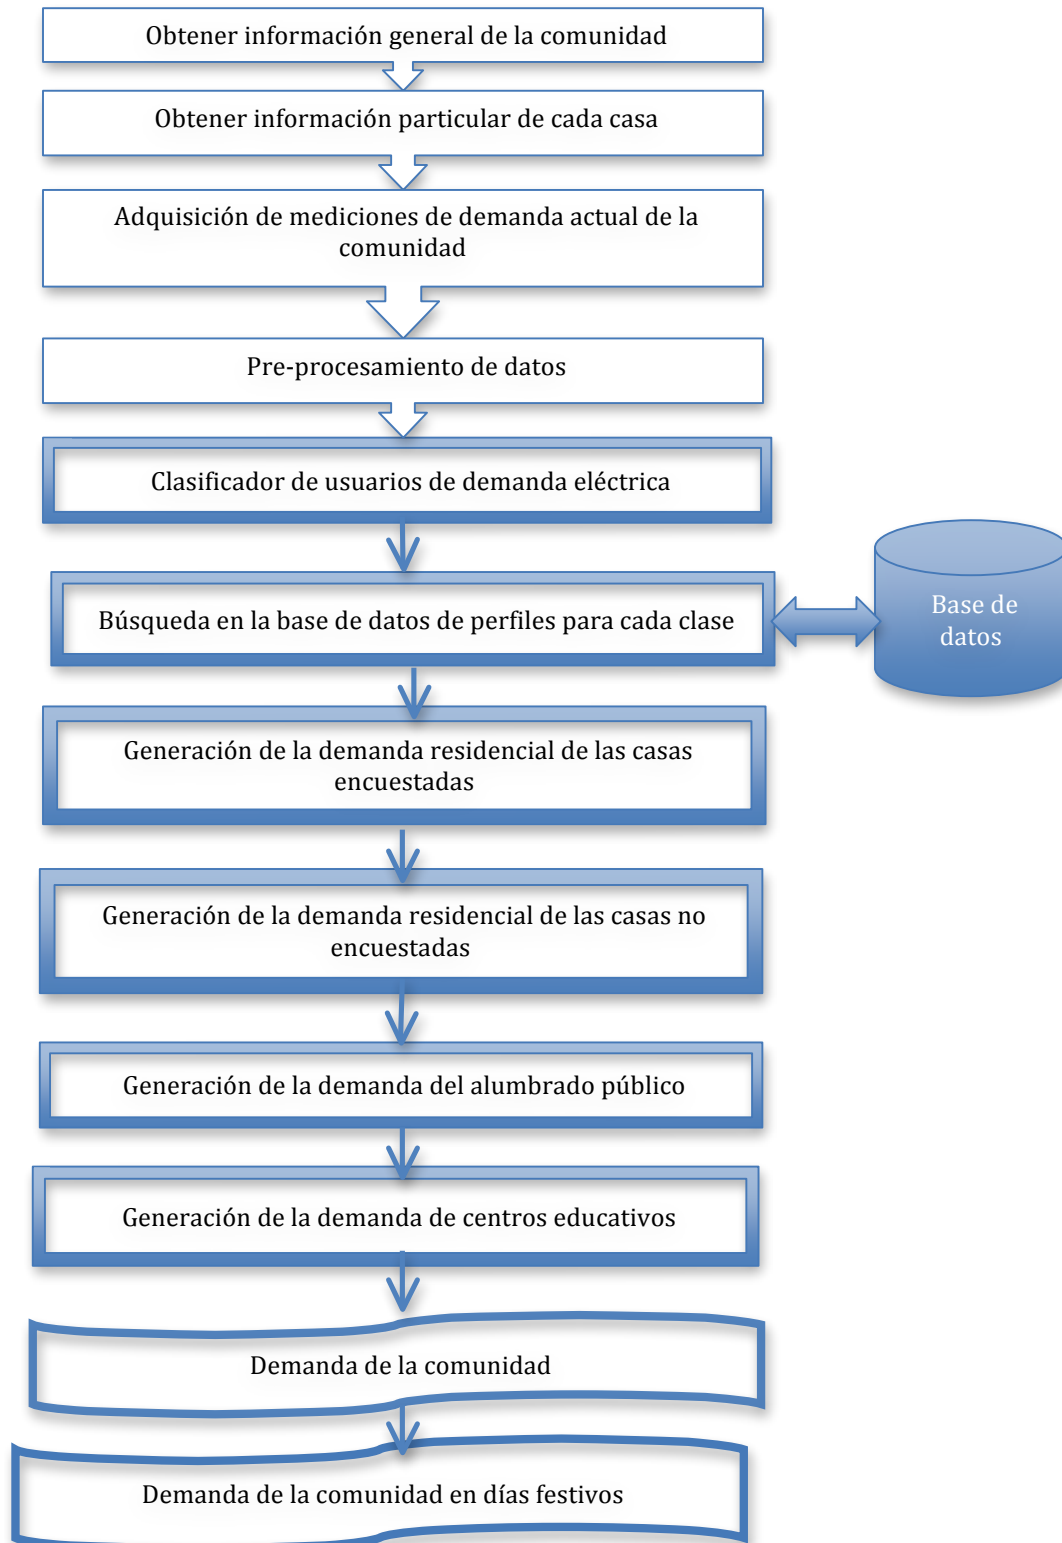


Figura 41 Secuencia del método de generación de perfiles de demanda eléctrica

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

El desarrollo computacional de la propuesta está realizado en MatLab. La propuesta busca ser flexible para distintos tipos de comunidades. En la Figura 42 se muestra un esquema general con los módulos que intervienen en este método propuesto donde se procesan las entradas para conseguir el perfil de demanda eléctrica se distinguen los siguientes módulos: un módulo de clasificación, un módulo de búsqueda que trabaja en paralelo con una base de datos de perfiles, usados para la generación del perfil residencial de las casas encuestadas, se dispone de un módulo de generación de perfiles residenciales de aquellas casas que no pudieron ser encuestadas, además de un módulo de generación del perfil del alumbrado público, otro de generación del perfil de centros educativos. Para el perfil de demanda incorporando días festivos se usa un módulo de generación de porcentaje de crecimiento. Cada uno de estos módulos se describe más adelante.

Los requerimientos para desarrollar un perfil de demanda en comunidades son:

- La comunidad cuenta con energía eléctrica por periodos de tiempo limitados en el día, o no disponen de ella por lo tanto no se dispone de un perfil diario de demanda.
- La información con la que se cuenta para la generación del perfil de demanda son únicamente encuestas.
- No se dispone de mediciones históricas de demanda eléctrica de la comunidad.

5.3 Estructura usada para el modelo de generación de perfiles de demanda

El método propuesto de generación de perfiles de demanda eléctrica en comunidades es una combinación de módulos que procesa las señales de entrada para obtener la demanda eléctrica (Figura 42). La demanda total de la comunidad se obtiene de la suma de la demanda del alumbrado público, de la demanda residencial de las casas encuestadas, demanda residencial de las casas no encuestadas, demanda de centros educativos. Además se consideran potencias máximas mínimas y promedio obtenidas del perfil actual de la demanda. La demanda residencial a su vez es la de mayor importancia y para su generación se usa como entradas: encuestas, un clasificador, un proceso de búsqueda en una unidad de almacenamiento o base de datos. Cada unidad se describe más adelante.

En método de generación de perfiles de demanda eléctrica se efectúa primero la obtención de las entradas que son de dos tipos: unas las generales, que dan la información general del pueblo como: número de luminarias, número de casas, número de escuelas, número de habitantes. Y otras de tipo individuales para lo que se usa encuestas individuales aplicadas a cada casa. Las encuestas individuales de cada casa van a una etapa de clasificación en donde de acuerdo a las características de cada una de las casas encuestadas se definen distintas clases, las características principales que definen estos grupos son: número de miembros, sus edades, ocupación de cada uno de ellos, ingresos económicos. Para la clasificación se utiliza mapas auto-organizados de Kohonen. Cada grupo entonces cuenta con características similares, a cada grupo se le asigna un perfil de demanda por una etapa de búsqueda a cada grupo. De este modo se cuenta con n grupos de m elementos que se multiplican por el perfil definido, al sumar los perfiles de cada

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

grupo se obtiene el perfil residencial de la comunidad de las casas encuestadas. La base de datos tiene perfiles de distintos tipos de familias en comunidades, y la búsqueda en cambio consiste en encontrar el perfil en la base de datos que corresponda a las características de determinado grupo. En la base de datos también se incluye perfiles de escuelas, encendido y apagado de las luminarias, que a su vez se multiplican por las entradas ingresadas que definen el número de cada uno de ellos. El perfil de la comunidad es obtenido de la sumatoria de los perfiles: residencial, luminarias y centros educativos.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

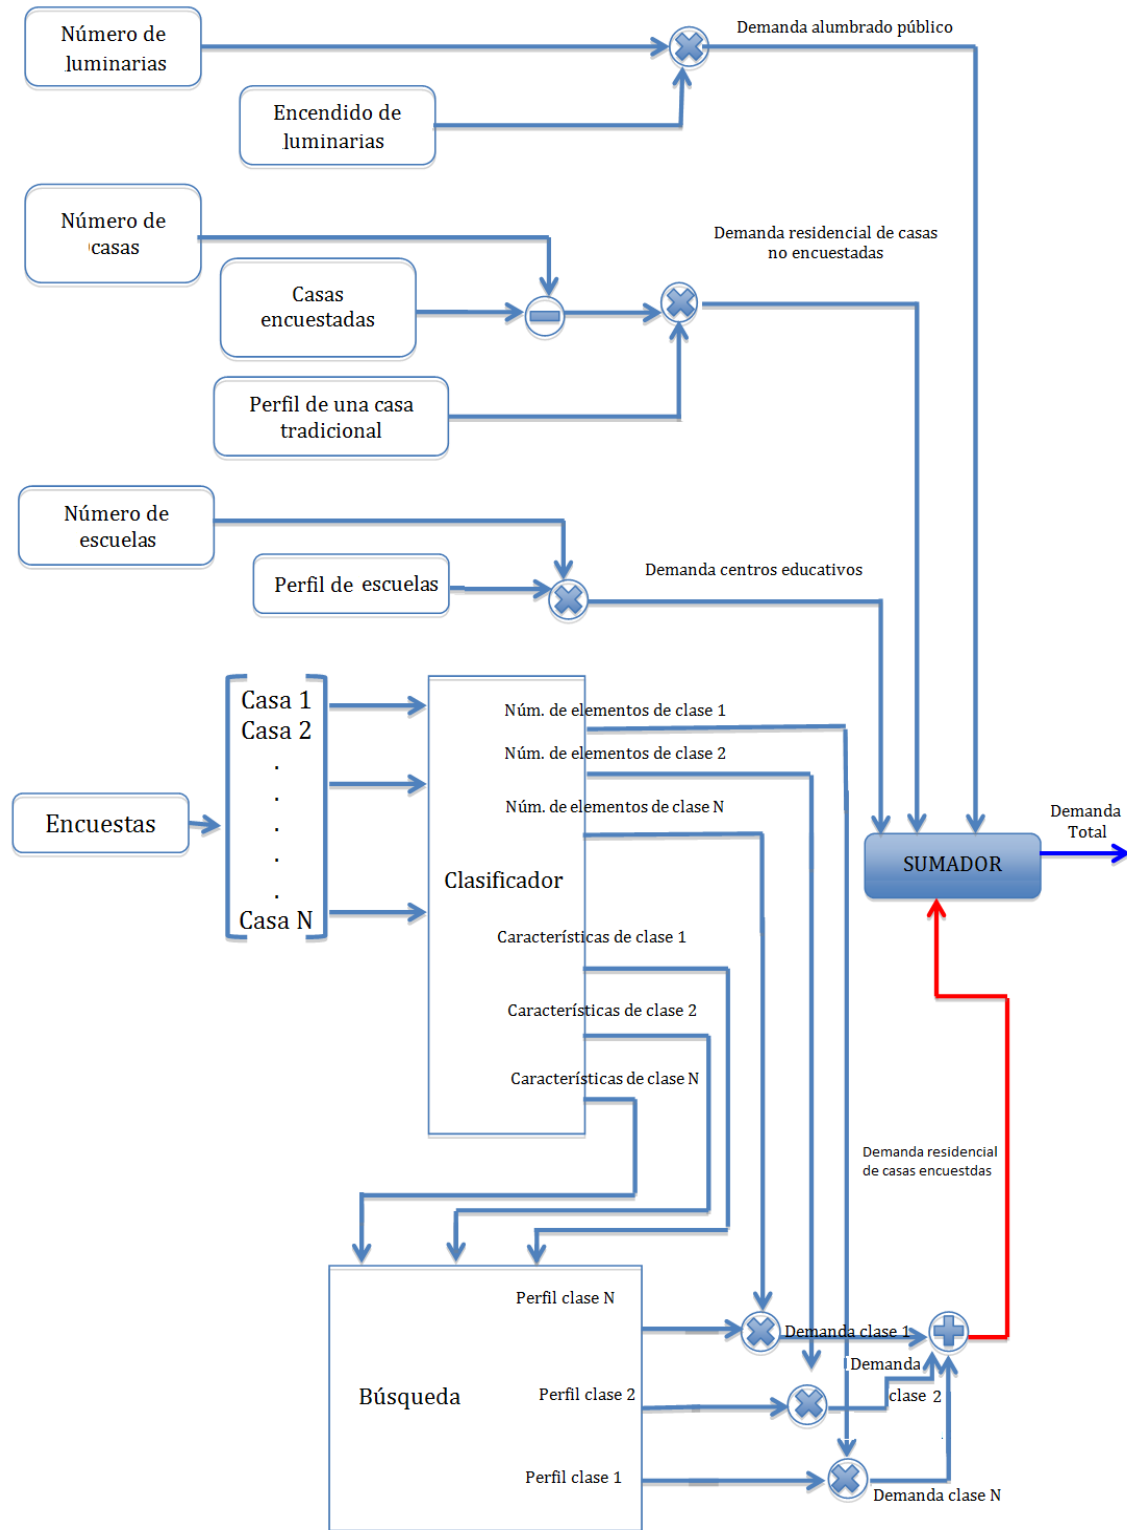


Figura 42 Estructura del modelo del generador predictor de eléctrica en una comunidad con días festivos

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 43 Estructura del modelo del generador predictor de eléctrica en una comunidad

5.4 Módulos de la estructura del generador de perfiles de demanda eléctrica en comunidades

Como se describió anteriormente el método propuesto incluye varios módulos entre ellos se encuentran: módulo de entradas del modelo, módulo de clasificación, módulo de búsqueda, base de datos, módulo generador del perfil de demanda eléctrica de: alumbrado público, centros educativos, casas no encuestadas, casas encuestadas y la generación de un factor que define el incremento de la demanda en días festivos.

5.4.1 Módulo de entradas del modelo

Las entradas del modelo se obtienen por medio de encuestas ya sean encuestas generales o individuales aplicadas a cada casa, y por información secundaria. En la Figura 44 se observa la secuencia recomendada para obtener las entradas. Se parte de una información general de la comunidad, luego se adquiere la medición de la demanda actual, para posteriormente por encuestas individuales obtener información particular. Todos estos datos requieren ser pre-procesados.

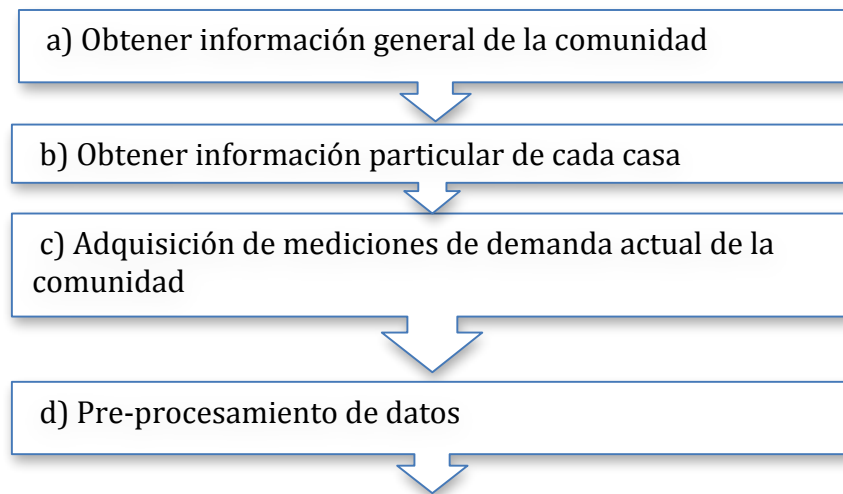


Figura 44 Flujograma para adquirir las entradas del modelo

a)

Información general de la

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

comunidad

Para obtener la información general de la comunidad se utilizan dos medios de recopilación de información: una que es información secundaria, para lo cual se usa revistas, documentos, datos estadísticos de diversas fuentes como: censos de población y vivienda, páginas web, revisión de informes o bibliotecas o consultando a los organismos correspondientes. Mientras que el otro medio es por visitas a terreno, en este caso se usa entrevistas a los representantes de instituciones pertinentes en la localidad, además se diseña una encuesta semi-estructurada para una muestra de la población, y se adquiere datos mediante observación directa o por mediciones [91].

Para obtener la información general se parte de la identificación de las variables influyentes, en la Tabla 5, se muestran las variables propuestas, información necesaria para la creación de encuestas a aplicarse.

Tabla 5 Variables en el proceso de recopilación de información.

Variables a definir usando información secundaria	Variables a definir a partir de observaciones y entrevistas realizadas en terreno
Ubicación	Conductas de consumo eléctrico en situación normal y durante festividades.
Salud	Número de casas
Número de habitantes	Número de escuelas, iglesias y centros de acopio
Clima	Ingresos y distribuciones
Educación	Actividades económicas más relevantes
Actividad Económica	Disposición a pagar por servicios básicos
	Dimensionamiento climático
	Caracterización de actividades cotidianas
	Organizaciones sociales
	Equipamiento (servicios básicos)
	Estado del sistema eléctrico

Determinadas las variables se aplica los instrumentos de recolección de información (información secundaria, visita a terreno). Mientras se realiza la visita a terreno para confirmar información previamente obtenida por información secundaria, se obtiene mediciones de la demanda eléctrica actual. Los resultados que se espera obtener son:

Ubicación geográfica : _____
 Nos permite conocer que tan aislados están, y que recursos renovables dispone la comunidad.

Número de casas : _____
 El perfil residencial se genera es en base al número de casas habitadas constantemente, y también es necesario conocer las casas que se habitan por temporadas.

Número de habitantes : _____

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

El número de habitantes permite conocer que tan chica o grande es una comunidad, y considerar en cuanto crece frente a días festivos.

Tipo de consumos : _____

Normalmente en comunidades el tipo de consumo es únicamente residencial pero sin embargo podría existir presencia de consumos comerciales, o a su vez consumos de microempresas, es importante identificar qué tipo de consumos presenta la comunidad. Además se puede identificar cuáles son las necesidades energéticas que no se satisfacen por imposibilidad de acceso pero que si se podría satisfacer una vez que se cuente con energía eléctrica, y proveer su crecimiento.

Presencia de microempresas, tiendas, restaurants, hoteles, hostales y horarios de funcionamiento.

Ante presencia de negocios nos da una idea de la importancia de obtener perfiles comerciales y no únicamente residenciales.

Salud si cuentan con dispensarios médicos : _____

De contar con dispensarios médicos hay que identificar que tan grandes son, y los horarios de atención, para poder también definir un perfil característico de estos centros.

Zonas de uso comunes : _____

Es necesario identificar cuantas y con qué frecuencia los habitantes acuden a estas zonas y el horario en el que se usan las áreas comunes, esto permitirá obtener el perfil de las zonas comunes que se suma al residencial.

Número de guarderías escuelas, colegios y sus horarios de funcionamiento: _____

Estos definen en cambio otro tipo de perfiles para lo cual se requiere del número de instituciones educativas y los horarios en los que son usados.

Estaciones climáticas, fenómenos naturales, y sus fechas: _____

Las estaciones climáticas son necesarias conocerlas, principalmente si se tiene estaciones muy marcadas esto influirá en el uso o la adquisición de electrodomésticos ya sea de calefacción o de aire acondicionado, caso contrario no será necesario disponer de estos equipos. Además es de importancia el conocer los fenómenos naturales que se presentan en la zona y en que fechas que se producen ya que esto altera la demanda porque muchas veces puede producir cierre de caminos, suspensión de actividades laborales, etcétera.

Estructura Organizacional : _____

Este dato es importante para posteriormente manejar incentivos en la gestión de demanda.

Días festivos o de mayor afluencia de gente : _____

Es necesario conocer los días festivos y si hay afluencia de gente, lo que se reflejara en un crecimiento de la demanda.

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Actividad económica de la comunidad : _____

Al caracterizar la actividad económica permite incluir en las encuestas individuales este aspecto.

Determinar número de luminarias del alumbrado público: _____

Cuantificar la cantidad de luminarias existentes en la zona y el tipo de luminarias de eso depende su consumo, es de gran importancia para poder definir el perfil de demanda por alumbrado eléctrico.

La fase de identificación de la comunidad determinará cuál es la demanda existente, nuevas fuentes de energía, dando respuesta a preguntas como: cuánta energía se necesita, dónde se necesita y si existe una capacidad real y voluntad para pagar por el nuevo suministro de energía si es el caso, o visualizar la estrategia de cubrir los costos en los que incurre. [33]

b) Información particular por casa.

Después de obtener información general de la comunidad se elaboran encuestas individuales. Con la encuesta realizadas a cada casa de la comunidad se obtiene información individualizada de los consumidores residenciales de energía, con ello se podrá conocer las conductas individuales, número de miembros actividades y edades de cada miembro, que permitirá después agrupar a familias de características similares, que se puedan definir con un perfil característico de demanda.

Se deben extraer principalmente las siguientes variables: número de personas en los hogares, edades y ocupaciones, ingresos económicos, producción, número de electrodomésticos, horarios actuales de uso de cada electrodoméstico.

La recaudación de información de cada casa, parte de la elaboración de instrumentos de recolección de información individual como: encuestas semi-estructuradas (denominadas así debido a que el entrevistador utiliza una pauta de temas en los cuales hay que basarse para realizar preguntas).

Muchas comunidades no cuentan con energía y si la tienen es por tiempo limitado, lo que hace necesario incluir preguntas que se proyecten al futuro.

La estructura de la encuesta completa que involucra distintas dimensiones se adjunta en el Anexo II, sin embargo en la Tabla 6 se muestran las preguntas que son específicamente de importancia para poder clasificar los hogares de una comunidad.

* ESUSCON (Energía Sustentable Cónдор)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Tabla 6 Preguntas de la encuesta que permiten definir el perfil de demanda

	Familia XXX	Familia XXXXX	Familia XXX
Número de miembros que viven en la casa			
Ingresos económicos mensual de la familia			
Edad miembro 1			
Edad miembro 2			
Edad miembro 3			
Edad miembro 4			
Edad miembro 5			
Edad miembro 6			
.....			
Edad miembro n			
Actividad miembro 1			
Actividad miembro 2			
Actividad miembro 3			
Actividad miembro 4			
Actividad miembro 5			
Actividad miembro 6			
.....			
Actividad miembro n			

De la primera etapa ya nos permite identificar las festividades y las fechas de afluencia en esta encuesta se busca identificar el número de personas que se incrementan por casa. Se analiza en la Tabla.

Tabla 7 Preguntas de la encuesta que permiten definir el perfil de demanda, principalmente cuantas personas se incrementan en fiestas.

En festividades cuantas personas se incrementan:		
Festivo	Fechas	Número de personas que se incrementan
Fiestas de xxxxx	Del xx/xx al xx/xx	#
Fiestas de xxxxx	Del xx/xx al xx/xx	#
Fiestas de xxxxx	Del xx/xx al xx/xx	#
Fiestas de xxxxx	Del xx/xx al xx/xx	#

Con respecto a los electrodomésticos, en la primera etapa se obtuvo una comprensión general de cuáles son los electrodomésticos de mayor presencia, eso permite en el momento de estructurar la encuesta individual definir cuáles y cuantos incluirlos, además identificar los horarios de uso, en el caso de contar con energía limitada, y a su vez como se proyectan al contar con energía permanente, y si posteriormente pretenden incrementar los electrodomésticos.

Los electrodomésticos sugeridos incluirlos en la encuesta son los de la siguiente lista pero pueden ir ampliándose de acuerdo a las características de la localidad.

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Bombillas, bombillas ahorradoras, decodificados, radio, DVD, computador, notebook, lavadora, secadora, aspiradora, refrigerador, hervidor, plancha, horno, jugüera, congelador, batidora, microondas, máquina de coser, soldadora, ventilados, estufa, parrilla, secador de pelo, alisador, ducha eléctrica, bomba.

Tabla 8 Encuesta del uso de electrodomésticos

	Actual	Futuro
	Electrométrico 1	Electrométrico 1
0:00	1	
0:30	2	
1:00	1	
1:30	2	
2:00	1	
2:30	1	1
3:00	1	
3:30	1	
4:00		
4:30		
5:00		
5:30		
6:00		
6:30		
7:00		
7:30		
8:00		
8:30		
9:00		
9:30		
10:00		
10:30		
11:00		
11:30		
12:00		
12:30		
13:00		
13:30		
14:00		
14:30		
15:00		
15:30		
16:00		
16:30		
17:00		
17:30		
18:00		
18:30		
19:00		
19:30		
20:00	1	
20:30	1	
21:00	1	
21:30	1	
22:00	1	
22:30	1	
23:00	1	
23:30	1	

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Selección de la muestra: La unidad de análisis la constituyen las familias, por tratarse de comunidades pequeñas, se sugiere realizar a cada casa las encuestas.

Además es necesario definir cómo llenar las encuestas para mantener uniformidad.

Para la encuesta planteada hay que considerar principalmente los siguientes aspectos:

- Si la encuetas se realizaran en campo de forma digital para su llenado seguir un estándar propuesto en el Anexo II.
- En la mayoría de los casos en los que se realizan encuestas de forma manual, se tiene que realizar una etapa extra de digitalización de la información. Esto principalmente porque el modelo acepta cierto formato.

Tras aplicarla encuestas realizada en campo, se procesa la información obtenida, para lo que se elaboran cuadros y gráficos estadísticos. Se analiza la información, tanto cuantitativa como cualitativa.

Los resultados esperados al aplicar las encuestas individuales son:

Número de miembros por casa -----

Con este dato se puede tener una idea de cuánto se consume a mayor usuarios mayor consumo.

Edades de cada miembro de la familia -----

La edad de los consumidores nos permite identificar el modo y que electrodoméstico son usados.

Ocupación de los miembros de la casa -----

Con esta información se puede respaldar los horarios de uso de la energía.

Electrodomésticos que tienen cada casa -----

En la encuesta conviene llenar cuantos electrodomésticos de este tipo disponen, con datos de “1” en el horario encendido y “0” apagado. Este información además nos permite identificar los electrodomésticos de mayor uso, y los horarios de uso, datos importantes a considerar cuando se realiza control de demanda, al conocer que electrodomésticos tiene mayor incidencia en la definición del perfil y además a que horarios pueden ser movidos sus consumos, con el fin de lograr aplanar perfiles diarios de demanda eléctrica, y disminuir los horarios de alto consumo.

c) Adquisición de mediciones de demanda actual de la comunidad

En esta etapa se instala la instrumentación necesaria para obtener el perfil de demanda diario de la demanda actual del sistema, aplicada a los terminales del transformador de distribución.

Partiendo del criterio del modelo de descomposición de una serie de tiempo se supone que una serie de tiempo $x(1), \dots, x(n)$, puede ser expresada como suma o producto de tres componentes: tendencia, estacionalidad, y un término de error aleatorio. Los tres modelos de series de tiempo más comunes se definen como:

Aditivo: $X(t) = T(t) + E(t) + A(t)$ Ec. 21;

Multiplicativo: $X(t) = T(t) * E(t) * A(t)$ Ec. 22;

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Mixto $X(t) = T(t) * E(t) + A(t)$ Ec. 23

Donde $X(t)$ es la serie de tiempo en el instante t , $T(t)$ componente de tendencia, $E(t)$ componente estacional, $A(t)$ componente aleatorio (accidental).

El perfil diario es usado para obtener, la demanda máxima, la demanda mínima en los tramos donde se cuenta con energía, para ser usados en el modelo propuesto.

Los valores extraídos de la medición actual del perfil son: demanda máxima (d_{max}^a), hora donde se produce la demanda máxima (h_{max}^a). Y se calcula el consumo diario ($C_{día}^a$).

Las mediciones son usadas para la compensación al perfil de demanda final generado, por lo que puede ser fácilmente excluida, principalmente para comunidades que no disponen de suministro eléctrico a priori.

d) Pre-procesamiento de datos.

En este punto se procesan los datos en formato específico para ser usadas como entradas del clasificador, en la etapa siguiente. Se realiza eliminación de datos erróneos, incorporación de datos ausentes, cambio en el tiempo de muestreo de los datos, asignación numérica de variables cualitativas obtenidas de encuestas, y normalización de los datos.

Se requiere disponer de encuestas digitales. Modificando las entradas en códigos numéricos, en la Tabla 9, se describe las asignaciones que se hace a las ocupaciones evaluadas en las encuestas, que puede ser incrementado si se observa presencia de otras actividades que no han sido incluidas.

Los resultados que se espera obtener son planillas de Excel bien ingresadas y lista para ser usadas en el clasificador se muestra en la tabla Tabla 10, el proceso de normalización está incluido en la función que realiza la clasificación.

Tabla 9 Asignación de valores numéricos a las ocupaciones de los habitantes

Número Asignado	Ocupación
1	Jubilado
2	Agricultor - chacra
3	Ama de casa
4	Estudiante
5	Trabajo jornada normal (horario de oficina)
6	Trabaja media jornada (día)
7	Trabajo media jornada (tarde)
8	Trabajo con jornada nocturna
9	Comercio desde casa
10	Ninguno de los anteriores

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Tabla 10 Entradas al clasificador

	Familia Hidalgo
Número de miembros que viven en la casa	2
Ingresos económicos mensual de la familia	100000
Edad miembro 1	78
Edad miembro 2	75
Edad miembro 3	
Edad miembro 4	
Edad miembro 5	
Edad miembro 6	
.....	
Edad miembro n	
Actividad miembro 1	1
Actividad miembro 2	1
Actividad miembro 3	
Actividad miembro 4	
Actividad miembro 5	
Actividad miembro 6	
.....	
Actividad miembro n	

En festividades cuantas personas se incrementan:			
Festivo	Fechas		Número de personas que se incrementan
	desde	hasta	
Fiestas patrias	18-09	19-09	2
Fiestas de año nuevo	30-12	31-12	2
Fiestas de virgen del Carmen	16-07	17-06	2
.....			

5.4.2 Clasificación de usuarios

Esta etapa tiene como objetivo principal encontrar una clasificación de forma no supervisada de clases de hogares de una comunidad, que atienda tanto a criterios conocidos a priori como número de miembros de la familia, la ocupación de cada uno de ellos, ingresos económicos, electrodoméstico con los que cuenta, etcétera. También se busca identificar cuantas familias corresponde a cada clase, usando un clasificador automático.

En este sentido, los mapas auto-organizativos de Kohonen [92] son un instrumento adecuado para la clasificación de datos ya que permiten que las clases o categorías sean creadas de forma automática, además de la proyección de vectores de dimensión n (clases creadas), en un espacio de dimensión 2, fácil de analizar de forma visual.

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

La clasificación de hogares se obtiene mediante una auto-organización, haciendo que las neuronas próximas (vecinas) respondan de una forma más fuerte a patrones de entrada similares. En nuestro caso, como medida de similitud se ha elegido la distancia euclídea.

Si bien es cierto SOM, no ocupa etiquetas de clases, los datos se podría etiquetar con el nombre de la familia a la que pertenecen las características, para que visualmente en los resultados tengan mejor entendimiento.

Las redes de Kohonen se caracterizan por su capacidad para clasificar un conjunto complejo de patrones de manera no supervisada, extrayendo criterios de clasificación no expresados de manera explícita [93]. Esta clasificación es llevada a cabo mediante la distribución de un espacio de entrada V_I (datos obtenidos de las encuestas efectuadas a cada casa de la comunidad), en un espacio de salida V_o de menor dimensión, preservándose las relaciones topológicas existentes entre los patrones de entrada. El espacio de salida viene constituido por un conjunto de neuronas ordenadas generalmente en un plano o una línea que pueden tomar forma rectangular o hexagonal, en el cual se define una función de vecindad como se visualiza en la Figura 45. La red auto-organizada debe descubrir rasgos comunes, regularidades, correlaciones o categorías en los datos de entrada, e ir incorporándolos a su estructura interna de conexiones. Las neuronas deben auto-organizarse en función de los estímulos es decir las entradas.




Figura 45 Disposición binaria de una red neuronal Kohonen.

Tras el proceso de aprendizaje, un vector de entrada $\vec{x} = (x_1, \dots, x_n)$, donde cada x_n representa: x_1 el número de miembros de la familia encuestada, x_2 edad del primer miembro de la familia, x_3 actividad que desempeña el primer miembro, x_4 ingreso económico, x_5 electrodoméstico con los que cuentan, etcétera, activará la neurona i del espacio de salida cuyo vector de pesos $\vec{w}_i = (\omega_{i1}, \dots, \omega_{in})$ tenga menor distancia al vector x . De esta manera, el vector \vec{w}_i podrá ser considerado como el prototipo de la región del espacio de entrada cuyos vectores activan a la neurona i . Finalmente, dos vectores de entrada similares según la relación definida en V_I , activarán la misma neurona o dos neuronas cercanas en el espacio de salida (Figura 46).

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 46 Representación esquemática de un espacio de n-dimensiones de entrada en un espacio bidimensional mediante un mapa Auto-organizativo de Kohonen.

La principal razón de la popularidad del SOM es su capacidad de presentar de manera automática un mapa en el cual se puede observar una descripción intuitiva de la similitud entre los datos; el despliegue bidimensional tiene la propiedad de presentar la información contenida en los datos de manera ordenada y resaltando las relaciones mencionadas [94].

La arquitectura de SOM planteada es una red neuronal formada por dos capas de neuronas. La capa de entrada que está formada por N neuronas (14 neuronas, cada neurona representa un atributo) una por cada variable de entrada, la descripción de cada neurona de la capa de entrada se incluyen en la

Tabla 12, esta capa se encarga de recibir y transmitir a la capa de salida la información procedente del exterior. La capa de salida formada por M neuronas (9 neuronas, $N_x=3$ y $N_y=3$), es la encargada de procesar la información. Las neuronas se distribuyen a lo largo de una retícula bidimensional, cada neurona constituye a un nodo de la retícula, la configuración o tipo de retícula puede ser definida como rectangular, hexagonal o incluso irregular como se aprecia e laFigura 47. Cabe señalar que la configuración hexagonal es más conveniente para efectos de visualización. La localización de la neurona sobre la retícula está representada por su vector de localización $r_i = (p_i, q_i) \in \mathbb{N}^2$, como se visualiza en la Figura 48




Figura 47 Arquitectura de SOM

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 48 Configuraciones más comunes en la retícula del SOM.

Las conexiones entre las dos capas que forman la red son siempre hacia delante, es decir la información se propaga desde la capa de entrada hacia la capa de salida. Cada neurona de entrada i está conectada con cada una de las neuronas de salida j mediante un peso w_{ji} . De esta forma, las neuronas de salida tienen asociado un vector de pesos W_j llamado vector de referencia (codebook), debido a que constituye el vector prototipo (promedio) de la categoría representada por la neurona de salida j . Así, SOM define una proyección desde un espacio de datos en alta dimensión a un mapa bidimensional de neuronas.

Entre las neuronas de la capa de salida, puede decirse que existen conexiones laterales de excitación e inhibición implícitas, pues aunque no estén conectadas, cada una de estas neuronas va a tener cierta influencia sobre sus vecinas. Esto se consigue a través de un proceso de competencia entre las neuronas y de la aplicación de una función denominada de vecindad (para nuestro caso gaussiana), que produce la topología o estructura del mapa.

El algoritmo de entrenamiento básico de SOM, primero inicializa los pesos de la red asignando a cada componente de los vectores de pesos números aleatorios. Luego se presenta un nuevo vector de entrada \vec{x} . Después se encuentra la neurona ganadora cuyos pesos están más próximos (en el sentido de la distancia Euclidea) al vector \vec{x} . Para posteriormente modificar el vector de pesos de la neurona ganadora y de sus neuronas vecinas utilizando la ecuación:

$$\vec{\omega}_i(t + 1) = \vec{\omega}_i(t) + l_r h_{iv}(\vec{x} - \vec{\omega}_i(t)) \text{Ec. 24}$$

Donde \vec{x} , el vector de entrada, $\vec{\omega}_i$ el vector de pesos de la neurona i , y $h_{iv}()$, la función de vecindad, determina el incremento del peso de cada neurona como una función de su proximidad a la neurona ganadora para el patrón \vec{x} . Generalmente, el área de vecindad viene dada por un cuadrado centrado en la neurona ganadora, cuyo lado decrece hasta cero a lo largo del entrenamiento. l_r Es la razón dinámica del aprendizaje, la cual evoluciona a lo largo del proceso de entrenamiento según la ecuación:

$$l_r(t) = \frac{l_{r0}}{(1 + \frac{ct}{nn})} \text{Ec. 25}$$

Siendo l_{r0} , la razón de aprendizaje inicial (0.3 en nuestro caso), c una constante (0.2), t la iteración actual y nn el número de neuronas de la red [95]. Finalmente se modifica el tamaño de vecindad y la tasa de aprendizaje. Este proceso se realiza consecutivamente cada que se va tomando una nueva entrada \vec{x} hasta que concluya el proceso de entrenamiento.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables. http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Durante la fase de entrenamiento, el SOM forma una red elástica que se pliega dentro de la nube de datos originales. El algoritmo controla la red de modo que tiende a aproximar la densidad de los datos. Los vectores de referencia del codebook se acercan a las áreas donde la densidad de datos es alta. Eventualmente unos pocos vectores del codebook están en áreas donde existe baja densidad de datos.

Una forma de visualizar las relaciones de cercanía entre los vectores de referencia de manera global es por medio de la matriz unificada de distancias, o matriz U, es el método más popular para mostrar SOM. Representa el mapa como una rejilla regular de neuronas, el tamaño y topología del mapa se puede observar en el gráfico donde cada elemento representa una neurona.

Cuando se genera la matriz U se calcula, a su vez, una matriz de distancias entre los vectores de referencia de neuronas adyacentes en el mapa bidimensional. Después se selecciona algún tipo de representación gráfica, por ejemplo una escala de grises. Los colores en la figura se seleccionan de modo que cuanto más oscuro es el color entre dos neuronas, menor es la distancia entre ellas.

Para resolver el problema planteado, hay varios toolbox disponibles, se utiliza el toolbox SOM versión 2.0, para Matlab desarrollado por Esa Alhoniemi, Johan Himberg, Juha Parhankangas and Juha Vesanto. Con ampliaciones y cambios en el código para resolver el problema planteado.

Los parámetros usados en este toolbox son los siguientes:

Inicialización de las neuronas: Se pueden usar de forma lineal o aleatoria 'lininit', 'randinit', en este trabajo se usó lineal.

Tamaño del mapa: Define el tamaño con coordenadas en dos dimensiones $N_x \times N_y$, o en forma de string (big, small), de manera proporcional, que permitiera observar los clustering de una manera explicativa.

Tipo de vecindad: La vecindad está en función de la distancia entre la neurona ganadora y sus vecinas. Las funciones pueden ser: Se usa la función Gaussiana, se puede lograr una mayor concentración de datos, logrando que cuanto más alejada sea la distancia de la ganadora, más pequeña será esta función.

Forma del mapa: La estructura del mapa puede ser de forma rectangular o hexagonal. Se usó hexagonal.

Ajuste grueso: Permite modificar la neurona ganadora, se utilizó varios valores, determinando como final el de 3000.

Ajuste fino: Con este ajuste podemos ajustar todas las vecindades y la ganadora de una misma proporción. Para este desarrollo se usó un valor 1000.

Además para la superposición del esquema de colores de la matriz U, para la visualización de SOM se asigna la grilla del espacio de salida con las dimensiones N_x y N_y (4 x 4).

La eficiencia del método SOM es medida por dos índices:

1. Error de Cuantización, que corresponde al promedio de la distancia Euclidiana de los vectores de datos a sus representantes más cercanos.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

2. Error Topológico, este error indica cual es la fracción de vecinos en el mapa, los cuales no tienen regiones de Voronoi en el espacio de datos.

5.4.3 Búsqueda en la base de datos

Para la búsqueda se utiliza técnicas de selección heurística. El objetivo es que a cada clase obtenida de la comunidad se le asigne un perfil determinado de acuerdo a parámetros y características comunes en una base de datos. En la Figura 49 se muestra un esquema general de la búsqueda en la base de datos. El clasificador toma las características de cada clase y luego las busca en la base de datos, una clase de iguales características, para capturar el perfil que le corresponde.

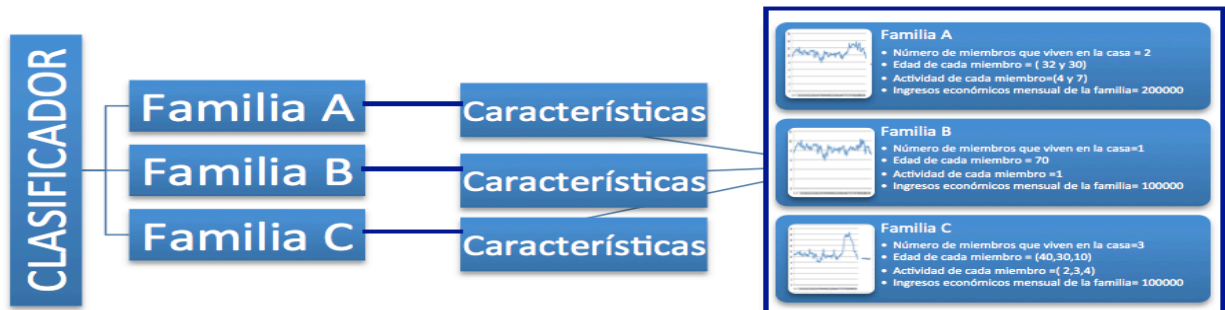


Figura 49 Esquema de búsqueda en la base de datos

Esta etapa se alimenta de la salida del clasificador específicamente de: la clase, las características de la clase, y número de elementos de cada clase. Según la característica de la clase se busca de forma heurística en una base de datos el perfil al que corresponde esa clase. La Figura 50 muestra la forma en que se realiza la búsqueda.

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

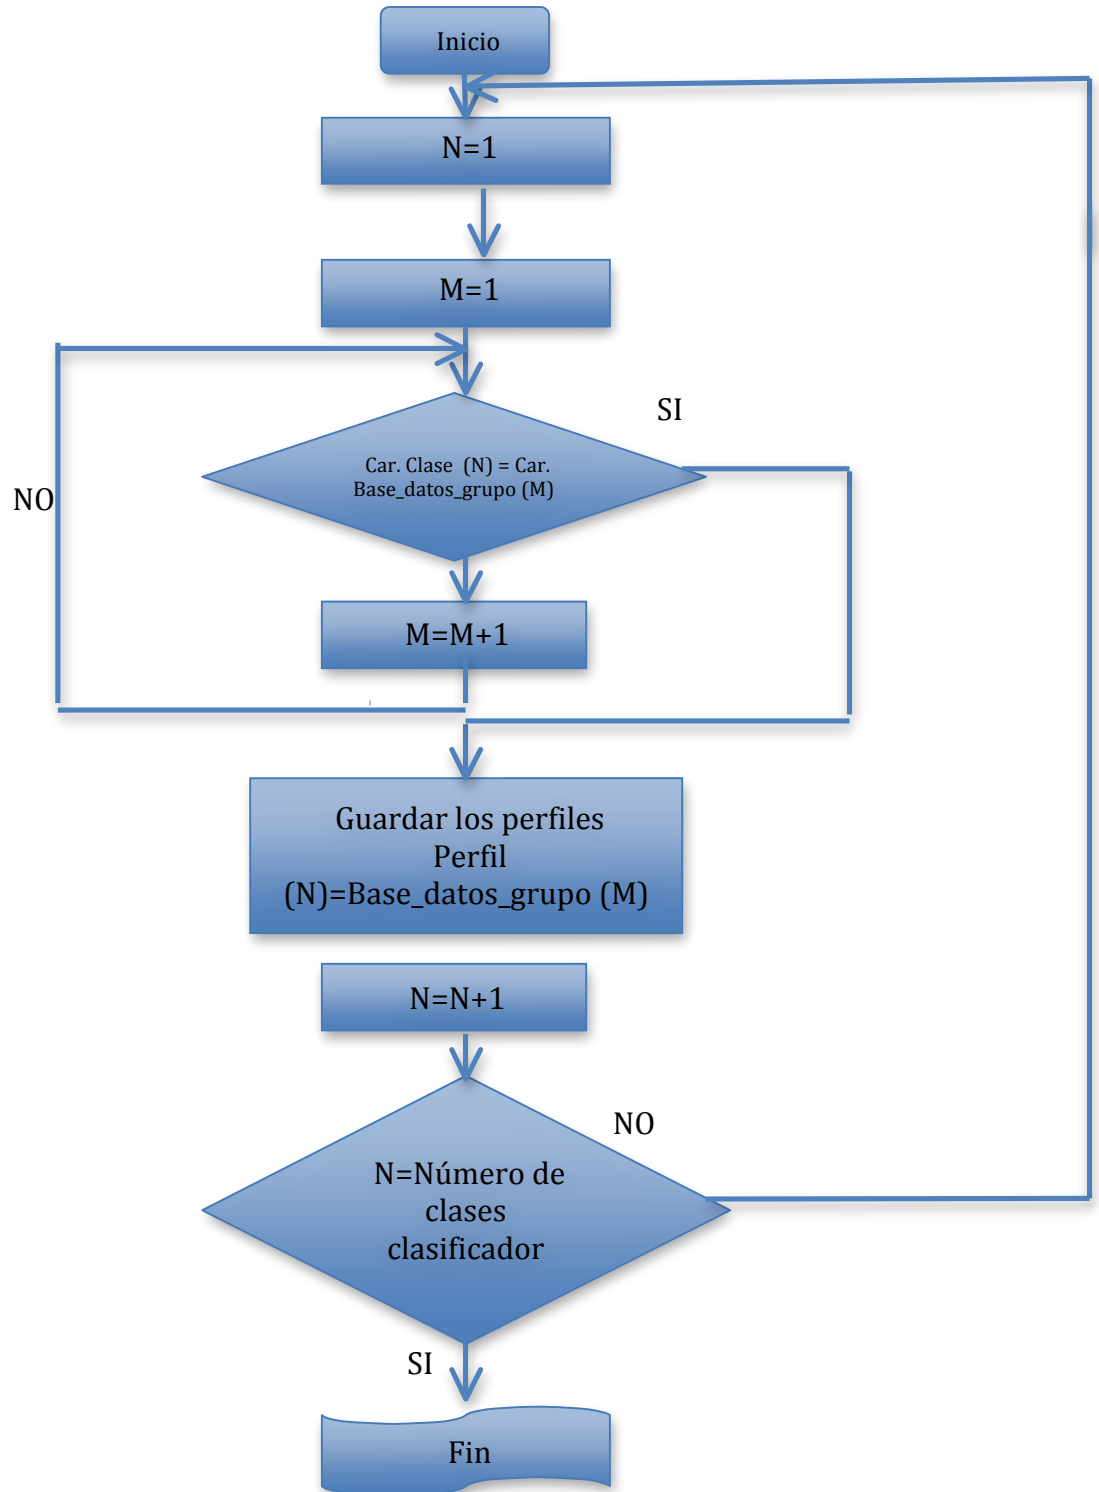


Figura 50 Algoritmo de búsqueda de perfiles de clases en la base de datos

De no existir el perfil correspondiente a determinada clase en la base de datos, en la búsqueda se le asigna un perfil denominado (no corresponde a ningún tipo). Este mismo perfil es usado para aquellas casas que no pudieron ser encuestadas.

Al detectar una clase nueva el perfil asignado a este grupo es necesario incorporarlo a la base de datos así se va enriqueciendo de información.

La búsqueda da como resultado: un perfil de demanda para cada clase existente, un perfil para casa no encuestadas.

5.4.4 Base de datos con distintos perfiles

La base de datos es donde se almacenan la mayoría de perfiles de demandada que caracterizan a determinada clase de familia. Mientras mayor número de perfiles exista se garantiza que cuando se realiza la búsqueda todas las clases tengan asignadas un perfil específico, que será usada en la etapa siguiente. No se dispone de mediciones para este trabajo, por tal motivo la base de datos fue creado a partir de un perfil de un casa modelo de cuatro miembros dos adultos y dos niños, de una zona rural de Ecuador, a este perfil se le fue modificando de acuerdo a aspectos que caracterizan a cada familia según análisis de las encuestas. En correcta operación de la propuesta de generación de perfil de demanda no será necesario ir tomando mediciones porque se espera tener ya una base de datos después lo suficientemente amplia por mediciones adquiridas a futuro del proyecto ESUSCON. La base de datos actual será remplazada por los perfiles producto de mediciones cuando se dispongan.

La base de datos se puede obtener únicamente en función de mediciones, en casas modelos.

Para lo que primero se selecciona una comunidad cercana al lugar de interés que disponga de energía ininterrumpida. Se instala la instrumentación necesaria en distintas casas de la comunidad cercana, y a la vez mediante una encuesta se extrae las características de esta casa con el objetivo de darle un identificativo a este tipo de casa. Se extrae las medición y con ello los perfiles, y las características que las diferencian una de otra para ser almacenados en la base de datos.

Al final lo que se pretende obtener es distintos perfiles asociadas a distintos tipos de casas, que con cada proyecto debe ir incrementado. En la Figura, se muestra los resultados que se obtiene de esta etapa. Actualmente la base de datos incluye once perfiles, la base de datos está sujeta a incrementar más perfiles. Los grupos incluidos en la base de datos son: pareja de adulto mayor, adulto mayor solo, adulto mayor con hijo adulto, adulto solo, pareja de adultos, pareja con un hijo niño, pareja de adultos con hijo joven, pareja con dos hijos niños, pareja adultos con dos hijos jóvenes, pareja adulta con más de tres hijos, y un perfil asignado para aquellas que no corresponden a ningún tipo.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 51 Perfiles de la base de datos del modelo generador de perfiles de demanda.

5.4.5 Módulos de perfil residencial de casas encuestadas

El perfil de la demanda residencial es el perfil de mayor relevancia en las comunidades, ya que cada cambio es significativo en el perfil. Se obtiene por la sumatoria de los perfiles de cada clase detectada en la comunidad.

Primero se obtiene el número de clases, número de elementos de la clase, perfil asignado para las clases. Para luego multiplicar el número de elementos de cada clase por el perfil asignado en la búsqueda.

5.4.6 Módulos de perfil residencial de casas no encuestadas

Por algún motivo ciertas casas no pueden ser encuestadas, en esos casos se obtiene el número de casas no encuestadas mediante la diferencia de la variable de entrada ‘número de casas’ y casas encuestadas, a este valor se le multiplica un perfil asignado para estos caso que es el mismo perfil asignado a clases que no encuentran un perfil o grupo en la base de datos, llamado (no corresponde a ningún tipo), en la base de datos.

La sumatoria del perfil residencial de casas encuestadas sumado al perfil residencial de casas no encuestadas, determina el perfil total residencial.

5.4.7 Módulos de perfil del alumbrado público

El encendido y apagado de las luminarias es dependiente normalmente de la claridad. Sin embargo se fija un perfil de referencia promedio.

La demanda total por alumbrado público se obtiene de:

$$D_l = n_l P_l b_l(t) \quad \text{Ec. 26}$$

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Donde D_1 es la demanda total del alumbrado público, n_1 es el número de luminarias existentes en la comunidad, P_1 la potencia que consume la luminaria, $b_1(t)$ es una variable binaria de encendido y apagado de las luminarias públicas en el tiempo, esta variable está almacenada en la base de datos.

Se obtiene como resultado la demanda total de alumbrado público de la comunidad, en la Figura 52, se muestra el perfil que describe el encendido y apagado de las luminarias.




Figura 52 Encendido de las luminarias del alumbrado público

5.4.8 Módulos de generación del perfil de centros educativos

En esta categoría se encuentran todos los centros educativos. Para esta aplicación se utiliza un perfil de demanda base de una escuela. Primero se establece el perfil de demanda eléctrica para un centro educativo, para este caso se obtuvo como perfil de referencia de una escuela localizada en el sector rural, dotado de los beneficios tradicionales de una escuela pública. Este proceso se realiza para cada centro, y de existir más de uno luego se suman los perfiles totales de cada centro educativo.

El perfil de la escuela usado en la base de datos se muestra en Figura 53, que luego se multiplica por número de centros educativos.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 53 Perfil por unidad de un centro educativo

5.4.9 Módulos análisis del perfil actual

Este módulo es principalmente para considerar el perfil actual y extraer de ahí características más importantes como demanda máxima y mínima. Es usado como un ajuste del perfil generado de la comunidad, se extrae de la demanda actual es decir limitada a determinado horario:

Demanda máxima (d_{max}^a), hora en la que se produce la demanda máxima (h_{max}^a). Además se calcula el consumo diario (C_d^a).

Demanda total de la comunidad.

La salida del modelo genera la demanda total de la comunidad, que es la suma de la demanda residencial, demanda por alumbrado público, y demanda de los centros educativos. Este modelo contempla también casas que no fueron encuestadas.

Una vez que se tiene la demanda total diaria de la comunidad se extrae: Demanda máxima (d_{max}^f), hora en la que se produce la demanda máxima (h_{max}^f). Además se calcula la cantidad de energía consumida en el día (C_d^f , [kWh/día]). Estos datos son usados para realizar una compensación a la demanda generada por la propuesta de ser necesario. Para su efecto se considera que la cantidad de energía consumida en el día del perfil generado en la propuesta C_d^f sea mayor o igual a la cantidad de energía consumida en el día del perfil actual es decir con energía limitada por horarios C_d^a , esto puede ser efecto de que existió un plan de ahorro energético antes, por esta razón este módulo es usado únicamente cuando previo no hubo una intervención de ahorro energético o a su vez considerando que ante una intervención de ahorro energético este no tuvo ningún impacto considerable. Esta compensación consiste en calcular una ganancia que está determinada por la diferencia entre C_d^a y C_d^f y a su vez esta ganancia es sumada a la demanda máxima del perfil generado la propuestas en la fig se describe esta operación.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

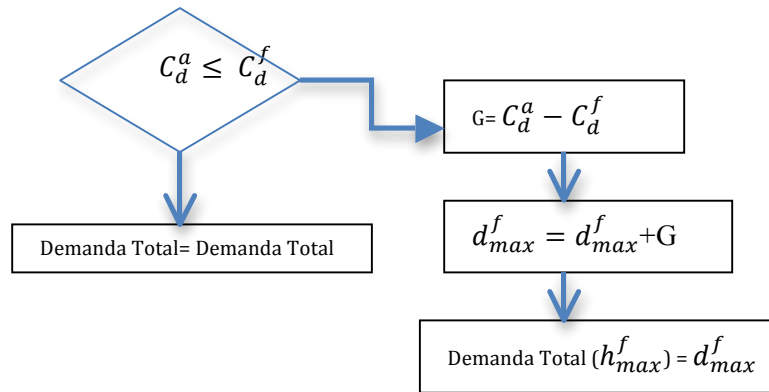


Figura 54 Ajuste de la demanda total de la comunidad generada

Las salidas generadas por esta propuesta son aproximaciones de la demanda, que puede producirse cuando una comunidad se beneficie de energía eléctrica ininterrumpida. Para una planificación en el tiempo será necesario realizar proyecciones para el número de años a proyectarse.

A la salida también se obtiene un perfil de demanda eléctrica al considerar que se trata de días festivos, donde la demanda normalmente se incrementa, que consiste en multiplicar a la demanda total por un factor calculado de acuerdo a las encuestas generales e individuales obtenidas.

5.4.10 Módulos de factor de incremento de la demanda eléctrica en días festivos

Para este caso se capturan todos los perfiles disponibles: d_r que es la demanda residencial de la comunidad, d_{ce} demanda de centros educativos. Se obtiene la demanda total d_t , de comunidad sumando todo las demandas diarias.

$$d_t(t) = d_r(t) + d_{ce}(t) + d_{pública}(t) \text{ Ec. 27}$$

A la sumatoria de perfiles $d(t)$, se le aplica el factor de días festivos $d_f(t)$ obtenida por:

$$d_f(t) = \frac{i_p}{H} * d(t) \text{ Ec. 28}$$

Donde $d_f(t)$, es la demanda que se incrementa en festivos, i_p es el incremento de personas, H el número de habitantes que tiene la comunidad normalmente, $d(t)$.

Se calcula la demanda total al considerar festivos es:

$$DF(t) = d(t) + d_f(t) \text{ Ec. 29}$$

La demanda total de la comunidad en festivos está determinada por la sumatoria de $d_f(t)$ y $d(t)$.

A la salida se obtiene el perfil total de la demanda de la comunidad, y el perfil en caso de días festivos.

5.5 Caso de Estudio (Comunidad Huatacondo)

La metodología propuesta es aplicada a la comunidad de Huatacondo, ubicada en el norte de Chile que cuenta con suministro de energía eléctrica desde las 14:00 horas hasta las 24:00 horas de lunes a viernes, y

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables. http://www.centroenergia.cl/ce-fcfm/?page_id=1004

desde 16:00 a las 24:00 los fines de semana. Para la generación del perfil de la demanda eléctrica de la comunidad de Huatacondo se sigue la propuesta planteada en la sección 5.4.

La primera etapa consiste en adquirir las entradas. Las entradas para el modelo son: número de habitantes, número de casas, número de escuelas, número de luminarias, y la medición del perfil de demanda actual, se obtienen por información secuencial y visita a terreno. Además de las encuestas individuales que son entradas ya más particulares.

1.- Obtener información general de la comunidad

Comprende de dos etapas una la información secuencial y otra la respuesta ante la visita a terreno

a.- Resultados al aplicar información secuencial

La información secuencial se obtiene de la siguiente fuente de internet <http://es.wikipedia.org/wiki/Huatacondo>, extrayendo la siguiente información:

Ubicación geográfica:

Huatacondo se ubica a 230 km al sureste de Iquique y a 118 km al noroeste de Ollagüe, en la Región de Tarapacá, Chile, en la Comuna de Pozo Almonte. Está ubicado en el antiguo Camino del Inca de Arica a Quillagua y en medio de la Pampa del Tamarugal, entre los cerros Amaculla (de 4.380 m de altura) e Higuierita (4.070 m).

Número de habitantes:

53 habitantes (según el Censo de 2002) [96].

Actividad económica de la comunidad:

En la época del salitre se producían frutos y flores. Actualmente producción de frutas y verduras en mínima cantidad. En las cercanías se encuentran petroglifos de Tamentica [91], y hay zonas donde quedaron registradas las huellas de animales prehistóricos [91].

Días festivos o de mayor afluencia de gente:

14 y 15 de agosto celebración de la Virgen del Asunción.

16 y 17, celebración del patrón del pueblo San Salvador.

18 y 19, celebración del Corpus Cristi.

20 y 21, octava de la Virgen.

b.- Resultados de la visita a terreno.

En la visita a terreno el grupo social del proyecto ESUSCON*, pudo extraer por una encuestas muy general realizadas a determinadas personas de la comunidad la siguiente **Tabla 11**

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Tabla 11 Resultados de la encuesta general aplicada a la comunidad de Huatacondo

Aspecto	Resultado	Horario de funcionamiento		Observación	Fuente
		Desde	Hasta		
Número de habitantes	72				ESUSCON *
Número de casas	31				ESUSCON *
Número de luminarias del alumbrado público	38	17:00	6:00	P= 200W	ESUSCON *
Número de micro- empresas	0				ESUSCON *
Número de tiendas barriales	1	7:00	20:00		ESUSCON *
Número de restaurants	0				ESUSCON *
Número de hoteles u hostales	0				ESUSCON *
Número de dispensarios médicos	1				ESUSCON *
Área común uno (Camping)	1			Camping	ESUSCON *
Área común dos (Iglesia)	1			Iglesia	ESUSCON *
Área común tres (Recreación)	1			Cancha de futbol	ESUSCON *
Área común cuatro	0				ESUSCON *
Número de centros educativos	1	8:00	14:00		ESUSCON *
Estaciones climáticas verano	0*			No tan marcada	ESUSCON *
Estación climáticas otoño	1*				ESUSCON *
Estación climática invierno	0*				ESUSCON *
Estación climáticas primavera	1*			No tan marcada	ESUSCON *
Fenómeno natural existente	1*			Invierno boliviano	ESUSCON *
Fenómeno natural existente	0*				
Festividad uno	Carnaval	2			ESUSCON *
Festividad dos	Semana Santa	4			ESUSCON *
Festividad tres	Cruces	5			ESUSCON *
Festividad cuatro	Tirana	16-jul	17-jul		ESUSCON *
Festividad cinco	Asunción de la virgen	14-ago	15-ago		ESUSCON *
Festividad seis	Fiestas patrias	18-sep	20-sep		ESUSCON *
Festividad siete	Navidad y año nuevo	24-dic	01-ene		ESUSCON *
Festividad ocho					ESUSCON *

En la visita a terreno se dejaron instalando medidores que registren el perfil actual de la demanda eléctrica.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcm/?page_id=1004

2.- Adquisición de mediciones de demanda actual de la comunidad

Se instaló medidores en los terminales del generador diesel para poder obtener el perfil de demanda eléctrica de la comunidad de al menos una semana y sacar un perfil de referencia en la Figura, se muestra la demanda eléctrica diaria actual de Huatacondo.



Figura 55 demanda eléctrica diaria actual de Huatacondo.

3.- Información particular de cada casa

a.- Los Resultados de las encuestas semi-estructuradas aplicadas a cada casa se adjuntan en el Anexo II, sin embargo en la

Tabla 12, se incluye la encuesta aplicada a una familia. La codificación numérica utilizada para las ocupaciones de los miembros de la familia, se muestra en la Tabla 13

Tabla 12 Encuesta aplicada a una familia de Huatacondo

Tipo	Características	Julio
Específicos	número_de_miembros	2
	edad_miembro_1	73
	edad_miembro_2	73
	edad_miembro_3	0
	edad_miembro_4	0
	edad_miembro_5	0
	edad_miembro_6	0
	actividad_miembro_1	1
	actividad_miembro_2	1
	actividad_miembro_3	0
	actividad_miembro_4	0
	actividad_miembro_5	0
	actividad_miembro_6	0
	ingreso_económico_promedio	150000

* ESUSCON (Energía Sustentable Córdor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Electrodomésticos	bombillas	Actual 3	0
	tv	1	0
	decodificador	0	0
	lavadora	1	0
	refrigerador	1	0
	hervidor	1	0
	plancha	1	0
	radio	1	0
	horno eléctrico	0	0
	maquina de cocer	0	0
	soldadora	0	0
	computador	0	1
	equipo_ música	0	0
	lámpara	0	0
	fluorescente	0	0
	foco_ incandescente	0	0
	DVD	0	0
	ventilador	0	0
	estufa	0	0
	jigüera	0	0
	congeladora	0	0
	batidora	0	0
	microondas	0	0
	aspiradora	0	0
	secador de pelo	0	0
	alisador de Pelo	0	0
	ducha eléctrica	0	0
bomba	0	0	
secadora_ropa	0	0	
licuadora	0	0	
notebook	0	0	
Aumento en la demanda	incremento promedio en festivos	2	

En festividades cuantas personas se incrementan:			
Festivo	Fechas		Número de personas que se incrementan
	desde	hasta	
Fiestas patrias	18-09	19-09	2
Fiestas de año nuevo	30-12	31-12	2
Fiestas de virgen del Carmen	16-07	17-06	2

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Tabla 13 Codificación numérica de la actividades de los miembros de la comunidad.

Codificación numérica	Ocupación
1	jubilado
2	agricultor - chacra
3	ama de casa
4	estudiante
5	trabajo con jornada normal
6	trabaja media jornada
7	trabajo con jornada nocturna
8	comercio informal desde casa
9	ninguno de los anteriores

4.- Pre-procesamiento de datos.

En esta etapa se verifica que las planillas de Excel estén bien ingresadas y lista para ser usadas en el clasificador.

En las Figuras 50 a la 52, se muestran un análisis general de los resultados de las encuestas en Huatacondo. En la Figura 56 se observa que el número de personas por casa, destacando que la mayoría de casas (9) son habitadas por dos personas, seguidos por aquellas casas que son habitadas por una persona, se puede notar que Huatacondo no cuenta con familias numerosas, únicamente presenta cuatro casas con cuatro miembros que es el mayor número de personas que forman estos hogares.

En la Figura 57 se resume las edades de los habitantes de Huatacondo, determinando que es una comunidad con gran presencia de adultos mayores (12 personas) entre 70 y 80 años, hay poca presencia de niños, y casi nada de jóvenes de 20 a 30 años. En la Figura 58 se describen las actividades de los habitantes de Huatacondo, y como era de esperarse ante alta presencia de adulto mayor en su mayoría viven de la jubilación, poco de agricultura y pocas dueñas de casa. Finalmente en la Figura 59 se detalla los electrodomésticos existentes en la comunidad con mayor presencia de televisores.

* ESUSCON (Energía Sustentable Córdor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 56 Número de personas que viven por casa




Figura 57 edades de los habitantes de Huatacondo

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 58 Actividades de los habitantes de Huatacondo.




Figura 59 Artefactos eléctricos de a localidad de Huatacondo (Proporcionada por ESUSCON *)

5.- Clasificación de Usuarios.

En esta sección se analiza el comportamiento del algoritmo SOM aplicado a la comunidad de Hutacondo, para resolver un problema de clasificación de tipos de familias de una comunidad aislada y su posterior visualización en dos dimensiones. Los datos de entrada tienen 14 atributos (dimensión) o neuronas de la capa de entrada (Tabla 14) y se dispone de 24 casas encuestadas. Se tiene información proveniente de la encuesta hechas en terreno a cada una de las casas de la comunidad en Febrero del 2010. Para determinar los vectores prototipos se utiliza SOM, mientras que para su visualización en dos dimensiones se usa la matriz-U. La capa de salida formada por 9 neuronas (grilla de $N_x=3 \times N_y=3$)

* ESUSCON (Energía Sustentable Córdor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Tabla 14 Entradas a la clasificación por SOM.

Tipo	Características	Julio
Específicos	número de miembros	2
	edad_miembro_1	73
	edad_miembro_2	73
	edad_miembro_3	0
	edad_miembro_4	0
	edad_miembro_5	0
	edad_miembro_6	0
	actividad_miembro_1	1
	actividad_miembro_2	1
	actividad_miembro_3	0
	actividad_miembro_4	0
	actividad_miembro_5	0
	actividad_miembro_6	0
	ingreso_económico_promedio	150000

Para la construcción de un mapa (SOM). En la Tabla 15, se muestran los parámetros de entrenamiento de este módulo.

Tabla 15 Datos para la construcción de SOM aplicado al toolbox.

Inicialización	Lineal
Tamaño del mapa	De dimensión $N_x=3*N_y=3$
Función de vecindad	Se considera una función Gaussiana , siendo esta una función decreciente en el tiempo.
Forma del mapa	Se considera una forma Hexagonal , porque es más conveniente para efectos de visualización.
Ajuste grueso	Permite modificar la neurona ganadora, se utilizó un valor 3000
Ajuste fino	Con este ajuste podemos ajustar todas las vecinas y la ganadora de una misma proporción. Se utilizó un valor 1000.

Condiciones usadas para la visualización:

Para la visualización SOM, se usa la matriz de distancias U (matriz unificada de distancia). Para obtener esta representación se obtiene la diferencia entre los valores de las cuatro o seis neuronas vecinas.

SOM permiten reducir la dimensionalidad de los vectores de entrada para representarlos mediante una matriz de distancias unificada (matriz U) generalmente consistente en una matriz 2D, apta para la visualización como una imagen plana. La matriz U permite la visualización en 2-D múltiples dimensiones. Esto se logra mediante el uso de relaciones topológicas entre las neuronas después de la finalización del proceso de aprendizaje. Este algoritmo genera una matriz donde cada componente es una medida de distancia entre dos neuronas adyacentes. Por lo tanto, se puede visualizar cualquier conjunto de datos

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

multivariable en 2-D. Mediante la matriz U se puede detectar las relaciones topológicas entre las neuronas e inferir sobre la estructura de los datos de entrada.

La idea básica de la representación U-matriz es: En la cuadrícula de dos dimensiones de la grilla de SOM, una neurona puede presentarse como un hexágono o un rectángulo. Con seis o cuatro vecinos respectivamente. En primer lugar, se calculan las distancias entre el vector de referencia de una neurona y el vector de referencia de sus vecinos. A continuación una neurona extra llamada distancia (d-neurona) se inserta entre las neuronas adyacentes. Por último, las d-neuronas son la sombra coloreados con una escala de grises que es proporcional a la distancia calculada entre la neurona y su vecino. Por ejemplo, si la distancia es grande, la d-neurona es oscura.

Por lo tanto, la inserción de d-neuronas entre las neuronas SOM aumenta el tamaño del original SOM. Por ejemplo, el original es de tamaño de 6x6 (36 neuronas) se convierte en 11x11 después de la inserción de la d-neuronas. Los clusters pueden ser vistos como "valles" (d-neuronas de color azul con o tonos claros), separadas por "colinas" (d-neuronas de colores con tonos oscuros). La ubicación relativa de los grupos en la U-matriz de visualización representa las similitudes en el espacio multidimensional.


La representación gráfica muestra que mientras más oscuras sean las zonas, más parecidas serán. Del mismo modo, mientras más claras sean significa que hay mayor diferencia de valores por lo que muestran una frontera entre neuronas que representan diferentes conjuntos de datos.

Se usa la proyección de la matriz U, con una rejilla SOM de 9 puntos de $N_x=3$ y $N_y=3$. La forma de validar es verificando manualmente los grupos creados.

En la Figura 60, se muestra de forma gráfica los resultados obtenidos. Se distinguen 7 grupos. Se visualiza rejillas de forma hexagonal, en distintas tonalidades de colores. Los grupos creados fueron verificados mediante clasificación manual notando coherencia de la clasificación. Se puede distinguir intensidades más fuertes en los colores, entre la clase 1 y la clase 4, esto principalmente porque de acuerdo a las características de cada clase la 1 está formado por dos adultos mayores jubilados, diferente a la clase 4 que primero tiene más integrantes son 4, segundo las edades de los miembros son distintas. En tonalidades más similar al de la clase 1 se encuentra la clase 6 esto principalmente porque se encuentran asociado por el número de miembros de la familia sin embargo las edades de los integrantes de la familia son diferentes lo que hace que se haya creado otra clase, de igual forma en tonos similares a la clase 1 se encuentra la clase 3, que difiere en la cantidad de personas que viven en cada casa, en la clase 3 vive únicamente un adulto mayor a diferencia de la clase 1 que es de dos, pese a que los elementos de la clase 4, al igual que la clase 3 están integrados por parejas de la tercera edad no pertenecen al mismo grupo es porque difieren en los ingresos económicos mensuales. En la parte superior se incluyen la clase 1,3 y 4, que tienen en común que sus miembros son adultos mayores, pero con diferencia en el número de miembros e ingresos económico, por eso mantienen cambios poco significativos en la intensidad de los colores, mientras que en la parte inferior se encuentran aquellas familias que primero son más numerosas superando a los 2 miembros, y sus miembros son adultos, si se compara la intensidad de las clases de la parte superior con las de la inferior son más notorias porque tienen diferencias más representativas, y en la parte intermedia derecha se encuentra el grupo 6, que pese a que tiene dos miembros no está completamente en la parte superior porque los miembros son jóvenes.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Se extrae la información necesaria para la siguiente etapa como: número de clase, características de cada clase, número de elementos pertenecientes a cada clase, los resultados se describen en la **Tabla 16**.



Clasificación con SOM: 14 atributos , 9 puntos, red hexa, funcion vecindad gaussian, inicialización lininit

Figura 60 SOM de clasificación de tipos de hogares de Huatacondo.

Tabla 16 Clases de hogares y sus elementos al aplicar SOM en Huatacondo

'clase 1'	'clase 2'	'clase 3'	'clase 4'	'clase 5'	'clase 6'	'clase 7'
'Felisa'	'Juan Hidalgo'	'Juan'	'Natalia'	'Yolanda'	'Carol'	'Jorge'
'Hilda'	'LuisB'	'Jorge'	'Félix'	'Nelly'	'Margarita'	'Viviana Barrios'
'Julio'	'Trinidad'	'Felipe'	"	"	'Mabel'	'Soledad Osa'
'Nora'	"	'Elvira'	"	"	'Victoria'	"
'Gregaria'	"	"	"	"	"	"
'Silvia'	"	"	"	"	"	"

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Base de datos con distintos perfiles

La base de datos se obtienen en función de mediciones, en casas modelos. La base de datos está formados por once grupos asignados determinados perfiles, cada grupo tiene características que los hacen diferentes unos de otros según se detallan en la Tabla:

Tabla 17 Grupos de la base de datos.

Grupo	Característica
1	Pareja de adulto mayores
2	Adulto mayor solo
3	Adulto mayor con hijo adulto
4	Adultos solo
5	Pareja de adultos
6	Pareja con un hijo niño
7	Pareja de adultos con hijo joven
8	Pareja adulta con 2 hijos niños
9	Pareja adultos con 2 hijos jóvenes
10	Pareja adultos con más de tres hijos
11	No corresponde a ningún tipo

En este caso se seleccionó para la base de datos un perfil de una zona rural de Ecuador, para posteriormente al disponer de mediciones remplazarlos por perfiles de la zona de Hutacondo, una vez que el sistema se encuentre operando correctamente.

6.- Búsqueda en la base de datos. Las salidas del clasificador son entradas del módulo de entre las que se tiene: la clase, las características de la clase, y número de elementos de cada clase, descripción que se encuentra en la Tabla 18 y Tabla 19.

Tabla 18 Entradas al módulo de búsqueda.

Clase	Elementos por clase	Una familia representante de la clase	Posición en la lista de encuestas
'clase 1'	6	'Feliza'	7
'clase 2'	3	'Juan Hidalgo'	19
'clase 3'	4	'Juan'	1
'clase 4'	2	'Yolanda'	16
'clase 5'	2	'Natalia'	2
'clase 6'	4	'Victoria'	13
'clase 7'	3	'Jorge'	18

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

Tabla 19 Salida del clasificador (características de cada clase)

		'clase 1'	'clase 2'	'clase 3'	'clase 5'	'clase 6'	'clase 4'	'clase 7'
		'Felisa'	'Juan'	'Juan'	'Natalia'	'Victoria'	'Yolanda'	'Jorge'
Características Comunes Por Grupo	'miembros_familia'	2	4	1	1	2	3	3
	'edad_miembro_1'	76	43	88	59	56	60	48
	'edad_miembro_2'	76	43	0	0	45	60	48
	'edad_miembro_3'	0	17	0	0	0	28	14
	'edad_miembro_4'	0	15	0	0	0	0	0
	'edad_miembro_5'	0	0	0	0	0	0	0
	'edad_miembro_6'	0	0	0	0	0	0	0
	'actividad_miembro_1'	1	5	1	3	3	3	5
	'actividad_miembro_2'	1	3	0	0	5	5	3
	'actividad_miembro_3'	0	2	0	0	0	5	2
	'actividad_miembro_4'	0	4	0	0	0	0	0
	'actividad_miembro_5'	0	0	0	0	0	0	0
	'actividad_miembro_5'	0	0	0	0	0	0	0
	'ingreso económico'	150000	100000	100000	220000	200000	150000	300000

El buscador toma la característica de cada clase y va buscando heurísticamente en la base de datos a qué grupo de los once corresponde, y captura el perfil que le caracteriza.

De no existir el perfil correspondiente a determinada clase en la base de datos, la búsqueda le asigna un perfil que corresponde al grupo número once (no corresponde a ningún grupo), este mismo perfil es usado para aquellas casas que no pudieron ser encuestadas.

Huatacondo cuenta con 7 clases, que después de la búsqueda los perfiles asignados a cada clase son los que se muestran en la Figura 61.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 61 Perfiles diarios que les caracteriza a las 7 clases de familias encontradas en Huatacondo.

7.- Demanda residencial de casas encuestadas

El perfiles asignados en la búsqueda a cada clase y se multiplica por el número de elementos década clase, obteniendo el perfil residencial por cada clase, que luego al sumarse determina el perfil total residencial de las casa encuestadas. El perfil residencial obtenido para Huatacondo es el que se muestra en la Figura 62.



Figura 62 Demanda eléctrica residencial de Huatacondo

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

8.- Demanda residencial de casas no encuestadas

Debido a que algunas casas no pudieron ser encuestadas se determina el perfil, multiplicando el número de casas no encuestadas que en este caso son 7 por el perfil asignado en la base de datos como (no corresponde a ningún tipo), la demanda obtenida de las casas no encuestadas se muestra en la Figura 63.




Figura 63 Perfil de demanda de casas no encuestadas de Huatacondo.

9.- Demanda de alumbrado público

En la base de datos se encuentra almacenado el encendido y apagado de las luminarias públicas en base a las cuales se determina un perfil característico de operación de una luminaria, obtenido por:

$$D_l = n_l P_l b_l(t)$$

Donde D_l es la demanda total del alumbrado público, n_l es el número de luminarias existentes en la comunidad, P_l la potencia que consume la luminaria, $b_l(t)$ es una variable binaria de encendido y apagado de las luminarias públicas en el tiempo.

D_l Es multiplicado por el número de luminarias existente en Huatacondo que en este caso son 32 que consumen 0.23 kW, y se obtiene el perfil total del alumbrado público de Huatacondo que se muestra en la Figura 64, correspondiente a un día tradicional de septiembre.

* ESUSCON (Energía Sustentable Cándor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 64 Perfil del alumbrado público de Huatacondo.

10.- Demanda de centros educativos

Huatacondo cuenta con un centro educativo, de once estudiantes, en la base de datos se tiene almacenado el perfil de escuela se lo multiplica por el número de escuelas. En la Figura 65, se muestra la demanda de la escuela.




Figura 65 Perfil de centros educativos en Huatacondo

Demanda total de la comunidad.

La salida del modelo genera la demanda total de la comunidad, que es la suma de la demanda residencial, tanto de casas encuestadas como aquellas que no fueron encuestadas, demanda por alumbrado público, demanda de los centros educativos. Este modelo contempla también casas que no pudieron ser

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

encuestadas, asignándoles un perfil. La demanda total de la comunidad de Huatacondo se muestra en la Figura 66.




Figura 66 Demanda eléctrica total de Huatacondo

A la salida también se obtiene un perfil de demanda eléctrica al considerar que se trata de días festivos, donde la demanda normalmente se incrementa, en la Figura 67, se muestra la demanda eléctrica considerando que es un festivos.




Figura 67 Demanda de Huatacondo generada ante días festivos

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

5.6 Validación y análisis de resultados del modelo propuesto

La validación del modelo propuesto es al aplicarlo en la comunidad de Hutacondo.

Las entradas son:

Número de habitantes (72), número de casa (31), número de escuelas (1), número de luminarias del alumbrado público (38), número de comercios (1), número de áreas comunes (2), y las encuestas individuales (formato Excel).

Se obtiene como salida:

La Figura 68, muestra la salida del modelo generador de perfil de demanda eléctrica en comunidades, comparada con el perfil real de Huatacondo al disponer de energía ininterrumpida, una vez puesto en marcha el proyecto ESUSCON*.

Al comparar estos dos perfiles diarios de demanda eléctrica se puede notar que la tendencia es similar, mientras que la cuantificación de la potencia es exagerada con respecto a la curva real.

Se observa zonas principalmente en las primeras horas que no coinciden con el perfil real esto es producto principalmente de la base de datos por no contar con mediciones reales, resta comprobar la completa veracidad al usar mediciones reales, en pruebas futuras.

Se puede notar en la curva que en los horarios donde se produce el máximo consumo del día es por la noche y se conserva ese criterio con el modelo propuesto, el perfil de la demanda generado por el modelo muestra una mayor potencia en las primeras horas de la mañana que el perfil diario real y en la parte central de la curva se aprecia una elevación mínima.

Este modelo busca la generación del perfil diario de demanda de una comunidad, usándolo de referencia para etapas de planificación, más no pretende ser una predicción por lo tanto no se busca que sea totalmente igual sino más bien que sirvan como referencia para nuevos proyectos de energización de comunidades usando recursos renovables, porque no se dispone de medición alguna, por tal motivo se hace un análisis cualitativo, más no cuantitativo que incorporen análisis de errores.

Este perfil puede ser usado para la planificación de proyectos de energización eléctrica en comunidades.

No se incorporo la salida para días festivo por que no existe una señal real de días festivos para poder compararla.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004




Figura 68 Demanda eléctrica real de Huatacondo versus demanda generada por el método propuesto.

5.7 Discusión

En este capítulo se planteó un modelo propuesto de generación de perfiles de demanda eléctrica en comunidades aisladas, considerando la particularidad de disponer de información de encuestas de la comunidad, y no se cuenta con históricos de mediciones de demanda eléctrica ininterrumpida de la localidad.

La ausencia de mediciones es justamente porque estas comunidades no disponen de energía las veinticuatro horas del día, y el perfil a generar es considerando que se cuenta con energía ininterrumpida. Este perfil posteriormente es usado como demanda de referencia para el desarrollo de proyectos de energización de comunidades aisladas.

El principal aporte de la herramienta de generación de perfiles de demanda en comunidades, es que pese a no contar con datos de mediciones de demanda eléctrica de la localidad tiene la capacidad de generar perfiles aproximados usando datos de encuestas de la comunidad. Con flexibilidad a ser usada en distintos tipos de comunidades, diferencias que se ven reflejadas en las encuestas que a su vez son entradas del modelo. Además el modelo al proporcionar perfiles aproximados de demanda favorece el desarrollo de proyectos de energización eléctrica en localidades aisladas, permitiendo dotar de energía y mejorar la calidad de la energía de estas zonas, destacando la inserción de energías renovables.

La herramienta computacional propuesta es desarrollada en MatLab, fácil de ejecutar donde el usuario tendrá que poner como entradas: número de habitantes, número de casas, número de escuelas, número de luminarias del alumbrado público, número de comercios, número de áreas comunes (obtenidas de la encuesta general aplicada) y las encuestas individuales (formato Excel). A su salida se obtiene el perfil

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

diario de la demanda eléctrica de la comunidad, y además el perfil de demanda al considerar días festivo, que por tratarse de comunidades aisladas en estas fechas incrementan la presencia de habitantes.

La estructura del desarrollo del modelo está formado por varias unidades: la primera llamada entrada del modelo que incluye obtener la información general de la comunidad, desarrollo y aplicación de las encuestas tanto generales como individuales, pre-procesamiento de los datos, las entradas al modelo tienen un formato en Excel especificadas en el Anexo 1. La segunda unidad es la de clasificación, que en base a las encuestas individuales realiza la clasificación N clases de tipos de hogares. La tercera unidad es la de búsqueda en la base de datos, consiste en obtener y asignar un perfil de demanda para cada clase encontrada en la clasificación, se unas las características de cada clase y se busca en la base de datos un perfil que coincida con las característica de cada clase encontrada, es decir para N clases habrá N perfiles asignados. La cuarta unidad considerada es la creación de la base de datos para lo que se requiere de mediciones en casas modelos. La quinta unidad consiste en obtener el perfil residencial que es la suma de los perfiles de cada clase. La sexta es la determinación del perfil de la demanda producto del alumbrado público. Las unidades sexta, séptima octava y novena, genera la demandad de centros educativos, centro médicos, comercio, áreas comunes respectivamente. Por último la decima unidad es la suma de todos los perfiles para obtener la demanda total de la comunidad.

Esta propuesta es validada en la comunidad de Huatacondo, obteniendo un perfil aproximado al real de la comunidad, pese a que la base de datos no fue creada con mediciones reales, se espera que al usar la información real mejores considerablemente los resultados, es necesario aclarar que los perfiles generados son aproximaciones.

Mientras más demandas eléctricas de hogares tipo incluyan en la base de datos mayor capacidad de aplicabilidad se tendrá y mejores resultados se obtendrán. Además es importante que la base de datos se exclusiva de zonas aisladas ya que el perfil difiere entre zonas urbanas y rurales.

Se puede notar que las comunidades en zonas aisladas se ven altamente influenciadas por características que describen a la comunidad como es el caso de Huatacondo que cuenta con un número grande de habitantes pertenecientes a adultos mayores, y mínimo a jóvenes por el fenómeno de la migración, aspecto presente constantemente en estos tipos de localidades.

Como trabajo futuros se plantea el mejorar la base de datos y con ello hacer una nueva evaluación de los resultados obtenidos.

* ESUSCON (Energía Sustentable Cóndor)- Huatacondo, micro-red inteligente basada en energéticos renovables.
http://www.centroenergia.cl/ce-fcfm/?page_id=1004

CAPÍTULO 6

PREDICCIÓN DE LA DEMANDA ELÉCTRICA EN MICRO-REDES

6.1 Introducción

La predicción de la demanda eléctrica a corto plazo de este trabajo es utilizada como entrada del EMS de la micro-red, localizada en Huatacondo. El caso de estudio que valida el modelo de predicción es planteado bajo dos escenarios. El primero al que se lo denomina “escenario 8 días”, que considera 8 días de medición, y un segundo escenario denominado “escenario 4 meses”, porque se considera 4 meses de medición, los dos escenarios son evaluados durante 25 días en ejecución.

Se plantearon los dos escenarios bajo el criterio que normalmente cuando empieza a operar una micro-red no se dispone de mediciones, pero mientras va pasando el tiempo los datos se van almacenando, y con mayores datos los modelos obtenidos son mejores.

Para la predicción de la demanda se plantea un modelo capaz de predecir con datos de únicamente ocho días para un entrenamiento inicial. Mientras que el escenario 4 meses, es cuando se cuenta con mediciones de demanda eléctrica de al menos 4 meses en donde es más aplicable las distintas metodologías de identificación de modelos de predicción.

La propuesta se basa en redes neuronales artificiales, con entrenamiento en línea, y es flexible la selección del periodo con el cual se quiere realizar los entrenamientos, por ejemplo para el escenario 8 días combine realizar entrenamientos más seguidos. Para el escenario 8 días el entrenamiento se ejecuta cada seis horas, mientras que en el escenario 4 meses, debido a que el modelo de partidas un modelo obtenido por identificación óptima se ejecuta cada dos días.

Este capítulo se ha estructurado primero describiendo al modelo y sus características, después se describe la metodología sugerida para la obtención del modelo, esta metodología es aplicada para cualquier tipo de variables a predecir. Después se incluye la evaluación del modelo con datos reales para el caso de estudio de la micro-red Huatacondo, primero bajo el escenario ocho días, para posteriormente evaluar el modelo bajo el escenario 4 meses al disponer de datos históricos de más tiempo. Con estos resultados se realiza una discusión para analizar sus resultados.

Finalmente se presenta modelos propuestos que no fueron validados. El modelo propuesto es con variaciones al validado en esta sección, debido a que incorpora una entrada más que es la medición de los registradores de pulsos instalados en determinadas casas de la comunidad, además que incluye una etapa de pre-procesamiento de las entradas usando transformadas wavelets, realizando la predicción en baja y alta frecuencia, para obtener la predicción final correspondiente a la suma de ambas.

6.2 Modelo predictor de la demanda eléctrica a corto plazo en micro-redes

Partiendo de la premisa que los modelos de predicción se basan en datos históricos pasados, es más difícil intentar predecir una variable usando poca información sin embargo se plantea un modelo capaz de predecir la demanda a corto plazo e ir mejorando las predicciones acorde se van incrementando sus datos históricos.

El modelo de predicción de demanda eléctrico propuesto es capaz de adaptarse a escenarios como el escenario 8 días, con pocos datos o escenario 4 meses, con mayor número de datos históricos. Se utiliza redes neuronales artificiales, con entrenamiento en línea.

La Figura 69, muestra las entradas usadas por el modelo propuesto que son: los datos históricos de la demanda disponible que varía de acuerdo al escenario que se analice, además el modelo se alimenta de mediciones de demanda eléctrica en línea, muestreadas cada quince minutos correctamente filtradas. El modelo es sensible ante errores en la medición por eso que las mediciones pasan por una etapa previa de verificación que es el filtro de mediciones, y en caso de presencia de mediciones incorrectas adquiere una entrada de respaldo, como medición. Además se dispone de una entrada que permite definir el tiempo que se desea para realizar el entrenamiento.

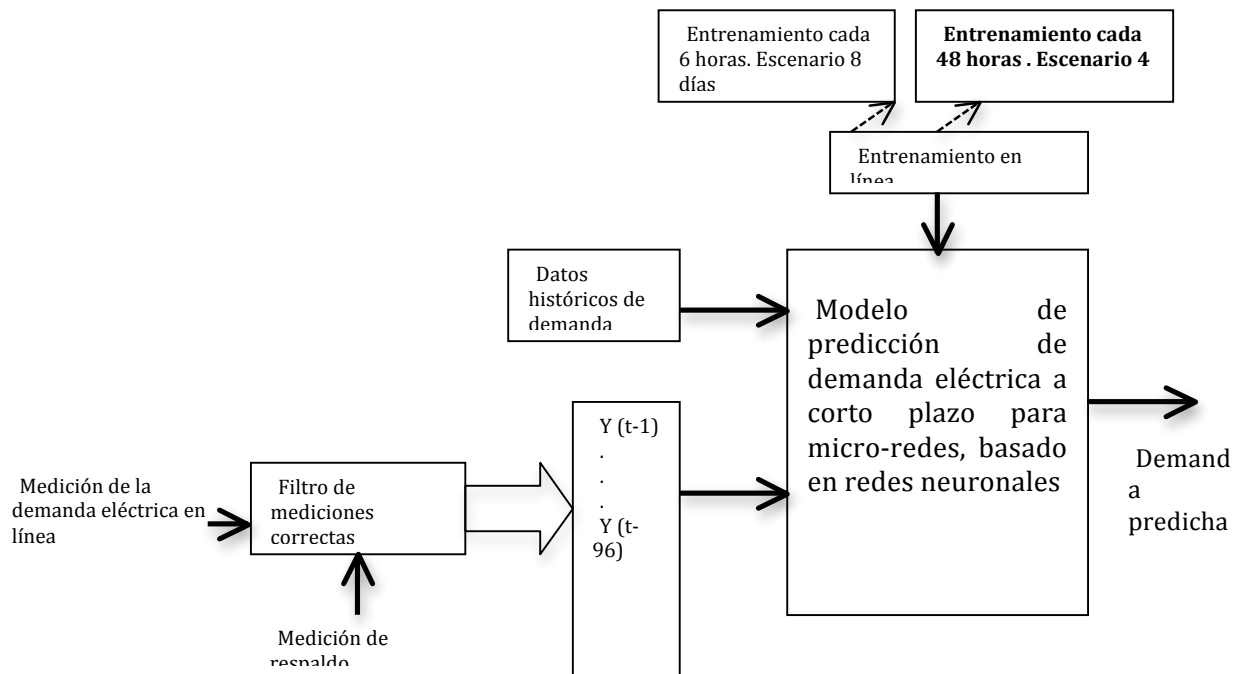


Figura 69 Entradas del modelo propuesto

Para el escenario 8 días se realizaron varias ejecuciones considerando entrenamiento cada hora, cada 2 horas, cada 6 horas, cada 12 horas, cada día, de todas esas pruebas se determino que realizarlo cada 6es la más óptimo dado que no es necesario hacerlo en tiempo menores porque el error de predicción no decrece, mientras que con entrenamiento a mayor tiempo el errores de predicción aumenta. Mientras que en el escenario 4 meses, por disponer de más datos los tiempos de entrenamiento se incrementa, y dado que el modelo con el que se inicializa está determinado por una identificación óptima, no hace falta actualizar los datos frecuentemente incluso puede ser analizado también sin entrenamiento en línea lo que significa que en la entrada de selección de tiempo para el entrenamiento es cero. Para el entrenamiento de la red neuronal se utiliza todo las mediciones que se van almacenando, mientras que para predecir utiliza 96 regresores que son equivalentes a un día pasado muestreado cada quince minutos. La salida del modelo está determinada por la siguiente expresión.

$$y(t) = \text{purelin}[\sum_{i=1}^8 W_i^{out} S_i + bias^{out}] \text{Ec. 30}$$

$$S_i = \text{tansig} [\sum_{j=1}^{96} W_{ji}^{in} X_j + bias_i] \text{Ec. 31}$$

Donde $y(t)$ es la señal estimada, W_i^{out} , pesos de capa de salida, $bias^{out}$ bias de la capa de salida, W_{ji}^{in} pesos de la capa de entrada y X_j las entradas del modelo

Características del modelo:

- Predicción de la demanda a 192 pasos es decir un horizonte de dos días muestreados cada quince minutos.
- Usa mediciones en línea de demanda eléctrica de cada quince minutos, para el entrenamiento en línea.
- Usa un día pasado como entrada al modelo de predicción.
- El modelo parte su ejecución únicamente con datos de una semana, y las predicciones irán mejorando en el tiempo.
- Las mediciones y las predicciones son muestreadas cada 15 minutos.
- Los errores de predicción del modelo, se manejan en el tiempo de acuerdo a la actualización de las mediciones.
- Entrenamiento supervisado en línea.

6.3 Metodología usada para el diseño del modelo de predicción de demanda eléctrica en micro-redes

Para la predicción de la demanda eléctrica se utiliza un modelo neuronal fundamentado en la secuencia general que se muestra en la Figura 70 Metodología general para el diseño del modelo de predicción de demanda, se parte de la adquisición de datos, luego se realiza el pre-procesamiento de datos, posteriormente se define aspectos a considerar para realizar la predicción como por ejemplo; tiempos de muestreo, horizonte de predicción, paso de predicción.

Seguido se define el tipo de modelamiento a usar para realizar la predicción de la demanda eléctrica, que pueden ser: modelos de regresión lineal o no lineal, modelos lineales como (ARX), modelos no lineales como (difusos, neuronales) o también conocidos como modelos de caja negra.

Este trabajo se enfoca en el uso de modelo neuronal y para la comparación se usa modelos lineales. Finalmente se obtiene la predicción de la demanda eléctrica.

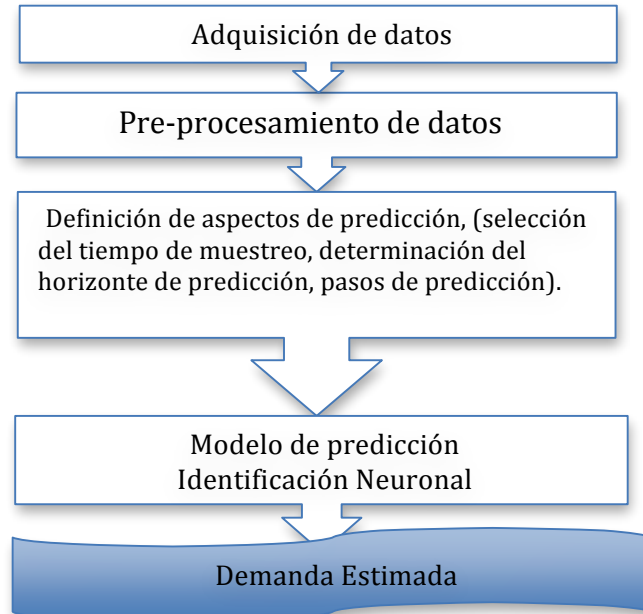


Figura 70 Metodología general para el diseño del modelo de predicción de demanda

Las tres primeras etapas son utilizadas para cualquier tipo de modelo de predicción a usar.

Adquisición de datos.

Se determina primero las variables medidas disponibles, ya que muchas de las veces un limitante es no disponer la instrumentación necesaria. Para predicciones es necesario disponer de la mayor cantidad de mediciones, reflejando así una variedad de estados principalmente para contemplar cambios de estaciones climáticas. Este punto marca la diferencia entre los dos escenarios por la particularidad del primer escenario es decir el caso en que no hay mediciones.

Pre-procesamiento de datos.

Una vez que se ha adquirido los datos hay que pre-procesarlos realizando: escalamiento, aumento de datos, corrección de datos.

Dado que los datos de mediciones de la localidad disponen de errores por ausencia de mediciones o presencia de datos irracionales propios de problemas de los instrumentos, se realizó un filtrado previo de los datos, además de modificaciones en el formato de emisión de los datos de los instrumentos a un formato uniforme.

Aspectos generales que definen la predicción

Es importante definir el uso que tendrá la predicción, en función de eso determinar: horizonte de predicción, pasos de predicción, tiempo de muestreo de las mediciones y en función de eso se desarrolla el predictor.

Modelación basada en redes neuronales

Este trabajo se enfoca como técnica de predicción en una de las estrategias más usadas en predicción de demanda eléctrica, desde muchos años atrás y que aún se sigue manteniendo, que es el uso de redes neuronales artificiales. Una mejor descripción de redes neuronales se adjunta en el Anexo IV.

La identificación neuronal comprende la secuencia mostrada en la Figura 71. Parte de la selección de las posibles variables de entradas del modelo, después se realiza la selección de datos, posteriormente se determina una estructura inicial de red neuronal, la misma que se irá modificándose hasta conseguir una estructura que sea óptima (etapa no usada cuando se trata de obtención de parámetros en línea), usando esta estructura se entrena la red obteniendo los parámetros o pesos y como se realiza repetitivamente se determinaran los más óptimos, después de tener la predicción de la demanda eléctrica y validando cada modelo, se obtiene errores de predicción por cada modelo, que luego son evaluados y el de menor valor es la estructuras más óptimas. A cada ciclo de ejecución se va modificando las variables de entradas es decir las neuronas de la capa de entrada, además se modifican el número de neuronas en la capa oculta, es decir ante cada entrenamiento la estructura del modelo neuronal también se modifica.

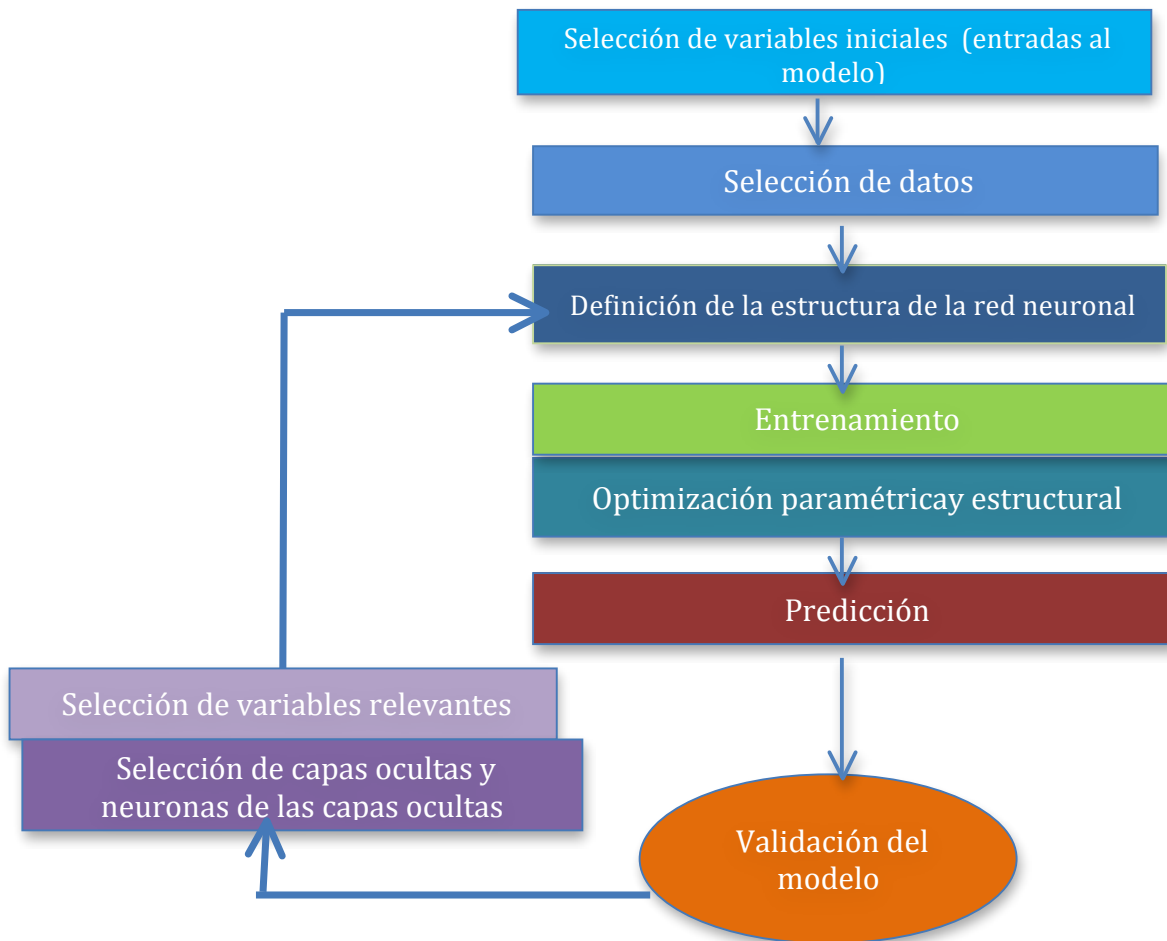


Figura 71 Identificación Neuronal

1.- Selección de variables iniciales

Consiste en analizar posibles variantes influyentes. Todo modelo parte de algunas alternativas de entradas pero una vez que se define que variables pueden ser medidas se determina las que mayor influencia tienen

en la variable a predecir. Esta etapa se la realiza como punto de partida de la identificación neuronal para determinar las variables de entrada al modelo de predicción de demanda eléctrica.

La técnica usada es análisis las correlaciones entre variables. Este consiste primero en analizar correlaciones entre las variables medidas (demanda eléctrica, potencia solar, velocidad de viento, radiación solar, humedad, temperatura) y de ellas determinar las más importantes. Además se analiza las correlaciones de la variable a predecir por meses y así poder analizar la influencia de las estaciones climáticas en la demanda eléctrica. También se recomienda el análisis de correlaciones de la demanda eléctrica de un día n con datos de una semana y ver la influencia con días similares. Finalmente se analiza correlaciones de las horas de la demanda eléctrica en un día.

2.- Selección de datos

Una vez ya determinadas las variables del modelo, se realiza la etapa de selección que consiste dividir los datos en tres grupos:

Datos de entrenamiento: Con este grupo de datos se obtienen los parámetros que definen al modelo cualquiera que este sea para este trabajo este conjunto de datos es el usado para identificar parámetros en los modelos ARX, y redes neuronales.

Datos de test: Este grupo de datos es usado también en la etapa de entrenamiento de la red neuronal, no se lo uso para el resto de modelos.

Datos de validación: Es un grupo de datos nuevos para evaluar el modelo total de predicción en base a este grupo se obtiene los errores de predicciones.

Los porcentajes definidos son de 60% para entrenamiento, 30% para test y el 10% para validación.

3.- Definición de la estructura inicial de la red neuronal

La estructura de la red neuronal comprende: número de neuronas de la capa de entrada, que es equivalente a las entradas de los modelos establecidas en la etapa de selección de entradas iniciales, para luego en el proceso de optimización determinar las entradas óptimas.

Número de capas ocultas. Para este trabajo en base a desarrollos anteriores se considerara una única capa oculta. El número de neuronas de la capa oculta, para una estructura inicial se parte del doble de neuronas de la capa de entrada, con función de activación no lineal tansig.

Una neurona a la capa de salida con función de activación lineal purelin.

Entrenamiento usado es Backpropagation supervisado y en línea.

Pesos, bias o parámetros, que se van actualizando a medida que se efectúe la optimización de la estructura.

4.- Entrenamiento

El entrenamiento utilizado es Backpropagation en línea para el escenario 8 días, se va ejecutando cada seis horas y mientras va actualizando mediciones se va entrenando y generando nuevos parámetros del modelo, mientras que para el escenario 4 meses el entrenamiento se lo realiza cada dos días, porque se parte de un modelo óptimo.

5.- Optimización de estructura

La optimización de la estructura neuronal consiste en determinar las entradas óptimas para obtener un predictor con errores mínimos, parte de un número determinado de entradas este se va modificando en cada interacción, la técnica utilizada es por análisis de error, que consiste en medir errores ante distintas combinaciones y reducciones de entradas y en función a ello se entrena predice, valida y se obtiene un error de predicción, los errores a evaluar son: MAPE, RMSE, la varianza del RMSE. De la misma forma optimizar el modelo incluye determinar cuántas neuronas son las más óptimas en la capa oculta. Para la selección de las entradas o variables relevantes se puede utilizar análisis de sensibilidad que consiste en derivar la salida en función de cada entrada y en función a ello determinar la de mayor influencia, o la técnica utilizada en este trabajo que consiste en prueba y error.

Una vez determinado el modelo óptimo se analiza ya los resultados finales con el conjunto de datos que no intervinieron en ninguna de las etapas anteriores. El modelo tiene la característica de estar ejecutándose y refrescándose los datos en línea.

6.- Predicción

El modelo de predicción es capaz de predecir en un horizonte de dos días o 192 periodos de quince minutos.

7.- Validación

En la Tabla 20. Se calcula los errores MSE, MAPE, varianza de MSE de predicción para cada tipo de estructura. La forma como se calcula es:

MSE (Mean Squared Error), se calcula por la siguiente expresión:

$$MSE = \frac{1}{N} * \left(\left(\sum_{i=1}^N (P_i - \hat{P}_i)^2 \right) \right) \text{Ec. 32}$$

MAPE (Mean Absolute Percentage Error), es calculado por:

$$MAPE = \frac{1}{N} * \left(\left(\sum_{i=1}^N \left(\frac{|P_i - \hat{P}_i|}{P_i} \right) \right) * 100 \right) \text{Ec. 33}$$

P_i Potencia real

\hat{P}_i Potencia estimada

N Número de punto de datos (1hora N=4; 12 horas N=48; 24 horas N=96; 48 horas N=192)

Y de ellos se determina el de menor valor seleccionando así el modelo óptimo.

$$std = \sqrt{\frac{1}{N-1} * \left(\sum_{i=1}^N (P_i - \bar{P})^2 \right)} \text{Ec. 34}$$

$$\bar{P} = \frac{1}{N} \sum_{i=1}^N P_i \text{Ec. 35}$$

Tabla 20 Errores para validar el modelo más óptimo

	Pasos	Tiempo	Pasos	Tiempo	Pasos	Tiempo	Pasos	Tiempo	Pasos	Tiempo
MSE	1	15 minutos	4	1 horas	16	12 horas	96	1 día	192	2 días
Var (MSE)	1	15 minutos	4	1 horas	16	12 horas	96	1 día	192	2 días
MAPE	1	15 minutos	4	1 horas	16	12 horas	96	1 día	192	2 días
Var (MAPE)	1	15 minutos	4	1 horas	16	12 horas	96	1 día	192	2 días

Demanda estimada

Se obtiene el modelo ya finalmente optimizado que es puesto en operación para someterse a entradas desconocidas y obtener errores que luego serán comparados con otros modelos de predicciones para determinar su rendimiento.

6.4 Caso de estudio (Proyecto micro-red Huatacondo)

La aplicación y validación del modelo de predicción propuesto se efectúa en la micro-red instalada en Huatacondo, bajo dos escenarios. El primero escenario 8 días, aplicado a la etapa inicial del funcionamiento de la gestión de la micro-red es decir cuando aún no cuenta con mediciones suficientes. Mientras que el escenario 4 meses es al considerar mediciones de cuatro meses.

Los modelos de predicción de demanda varían únicamente en el entrenamiento para el escenario uno utiliza entrenamiento en línea cada seis horas, mientras que en el escenario dos usa entrenamiento en línea cada dos días.

En lo que a la metodología aplicada para el diseño del modelo se refiere también hay variantes principalmente en la etapa de identificación neuronal.

A continuación se describe primero la metodología para determinar el modelo bajo los dos escenarios, y luego el modelo funcionando bajo los dos escenarios.

6.4.1 Aplicación de la metodología para el diseño del modelo de predicción de demanda eléctrica bajo el escenario 8 días, al no disponer de mediciones históricas

En esta sección se valida el modelo de predicción basado en redes neuronales con entrenamiento en línea que usa como entradas la demanda pasada de un día. Para el diseño del modelo de predicciones, se utiliza la secuencia que se muestra en la Figura 72. Se parte con la adquisición de datos se pre-procesan, definidos los aspectos de predicción, se realiza la identificación neuronal para este caso los datos son de apenas 8 días, para obtener el modelo inicial de predicción, el mismo que cada 6 horas ira identificando parámetros con el entrenamiento.

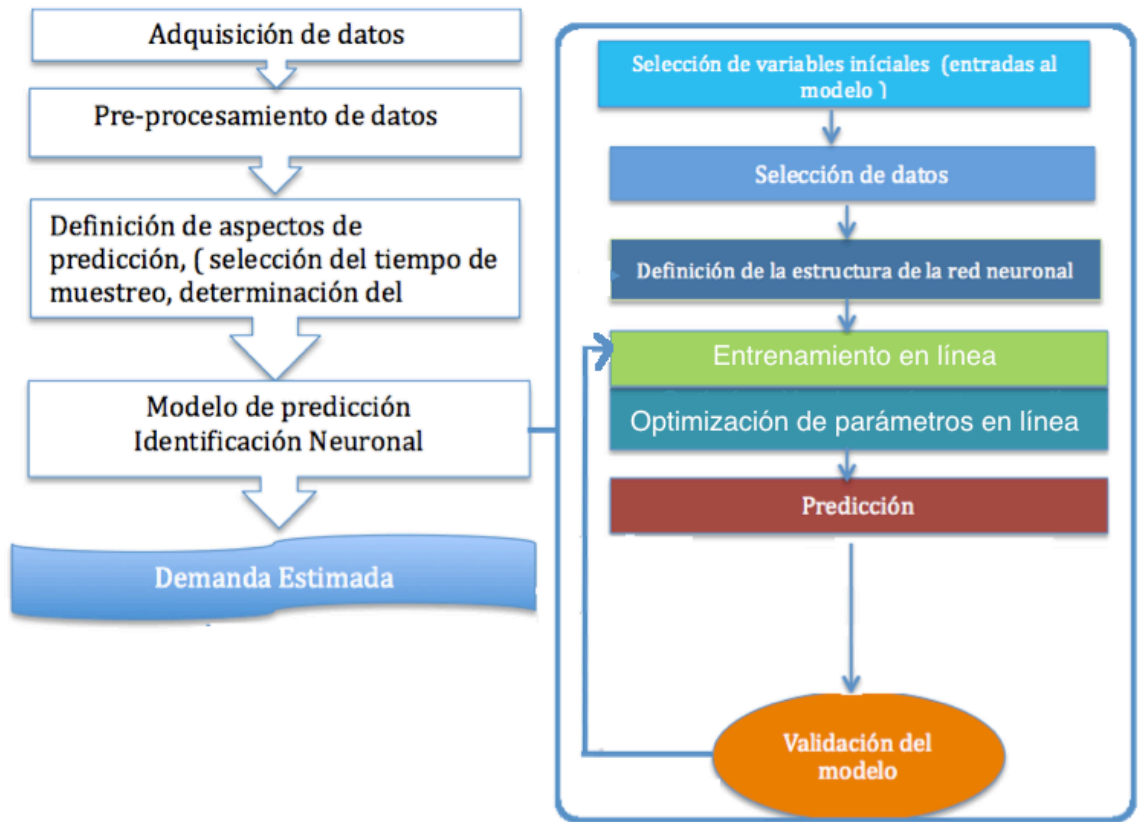


Figura 72 Metodología para obtener el modelo de predicción de demanda eléctrica bajo el escenario uno.

Adquisición de datos y pre-procesamiento de datos.

Debido a que en este escenario se considera únicamente mediciones de ocho días los datos adquiridos y pre-procesados corresponden a las variables: potencia solar, demanda eléctrica, velocidad de viento, radiación solar, temperatura desde el 01/01/2011 hasta 08/01/2011.

Aspectos generales que definen la predicción

Uso: Las predicciones son utilizadas como entrada del EMS, para la micro-red Huatacondo en modo deslizante, el optimizador se ejecuta cada 15 minutos para 2 días.

Tiempo de muestreo de las mediciones: Cada 15 minutos.

Horizonte de predicción: De 48 horas (2 días, 192 puntos de medición)

Pasos de predicción: 192 pasos, equivalente a dos días.

Modelación basada en redes neuronales

1.- Selección de variables iniciales

Pese a contar con poca información se analiza correlaciones, entre las variables disponibles, sus resultados se muestran en la Tabla 21, obteniendo correlaciones bajas entre la demanda eléctrica y el

resto de variables descartando incorporarlas como entradas del modelo y considerando únicamente la demanda eléctrica pasada como entrada.

Tabla 21 Correlación entre variables (escenario uno)

	Demanda	Potencia solar	Velocidad del viento	Temperatura	Radiación solar	Húmeda
Demanda	1.000	-0.272	-0.080	-0.129	-0.278	0.287
Potencia solar	-0.272	1.000	0.622	0.827	0.994	-0.717
Velocidad del viento	-0.080	0.622	1.000	0.794	0.634	-0.561
Temperatura	-0.129	0.827	0.794	1.000	0.851	-0.780
Radiación solar	-0.278	0.994	0.634	0.851	1.000	-0.735
Humedad	0.287	-0.717	-0.561	-0.780	-0.735	1.000
Registros de pulsos	-	-	-	-	-	-

La Figura 73, muestra el diagrama de las correlaciones analizadas. Se sugiere hacer un análisis de correlación por días similares, e influencias de estaciones climáticas, pero al no disponer de mediciones se analiza correlaciones de la demanda en un tiempo t con demandas de tiempos pasados en la Figura 74 se muestra la influencia de varias regresiones, muestreadas cada hora, se puede distinguir que las regresiones de veinticuatro horas pasadas son influyentes para la predicción de la demanda en un tiempo t.




Figura 73 Correlaciones entre variables escenario uno




Figura 74 Correlaciones de tiempos pasados con el dato a predecir

Después de hacer el análisis de correlación se determina como entradas las de la Tabla 22, es decir las mediciones de un día pasado, en este escenario no se realiza la optimización, es decir se elimina la identificación de parámetros fuera de línea porque no se cuenta con datos, así que el modelo óptimo está identificado por la estructura de la red inicial.

Tabla 22 Entradas del modelo de predicción de la demanda eléctrica (escenario uno)

	Representación en el tiempo	Regresores
Demanda pasadas	1 día pasado	$y(t-1), y(t-2), y(t-3), \dots, y(t-96)$

2.- Selección de datos

Los datos usados para el entrenamiento inicial de donde se obtienen los parámetros iniciales que luego irán cambiando ante cada entrenamiento son de una semana, que se describen en la Tabla 23 y como lo sugerido en la metodología de diseño del modelo se dividen en los porcentajes preestablecidas.

Tabla 23 Porcentaje de datos para definir el modelo neuronal inicial

	Porcentaje	Número de datos	Desde	Hasta
Datos de entrenamiento	60	461	02/01/2011 00:00	06/01/2011 19:00
Datos de test	30	230	06/01/2011 19:15	09/01/2011 04:30
Datos de validación	10	77	09/01/2011 4:45	09/01/2011 23:45

3.- Definición de la estructura de la red neuronal

En este escenario la estructura considerada no es la óptima, ya que esta etapa primero que se la realiza fuera de línea y segundo requiere de datos, pero en todo caso la predicción va mejorando a medida que el entrenamiento vaya contando con más mediciones, cambiando los parámetros del modelo, pesos y bias, pese a que su estructura no cambie.

Tabla 24 Estructura de la red neuronal para el predictor de demanda eléctrica

Estructura inicial de la red neuronal	
Número de capas	3
Número de capas ocultas	1
Neuronas de la capa de entrada o entradas del modelo	96
Neuronas de la capa oculta	12
Neuronas de la capa de salida	1
Función de activación de la capa oculta	Tansig
Función de activación de la capa de salida	Purelin
Entrenamiento	Backpropagation
Tipo	Supervisado en línea cada hora

4.- Entrenamiento

El entrenamiento es supervisado en línea se ejecuta cada seis horas, actualizando pesos y bias del modelo.

5.- Optimización de estructura

Esta etapa es excluida para este escenario debido a la carencia de datos, al disponer de mayores mediciones se debe reajustar el modelo inicial incorporando optimización del modelo.

Resultados de predicción del modelo predictor de demanda eléctrica bajo el escenario con 8 días

Los resultados incluidos son con datos reales asumiendo que el modelo esta prediciendo en tiempo real, y se va alimentando de mediciones reales en línea cada quince minutos, con entrenamiento en línea, es decir actualizando los pesos y bias del modelo neuronal cada 6 horas, bajo estas consideraciones en la Figura 75 se muestra la predicción de la demanda eléctrica versus la demanda eléctrica real, en el primer entrenamiento de la red neuronal con datos de únicamente ocho días pasados, y utilizando como entrada del modelo la demanda eléctrica de un día pasado corresponde al 09/01/2011 desde las 00:15, hasta el 10/01/2011 00:00, ante la cual se obtiene como salida la predicción de demanda para dos días desde el 10/01/2011 00:15 hasta el 12/01/2011 00:15. Como era de esperarse los resultados no son los mejores presentan un MAPE de 55.1849%, sin embargo la tendencia en la predicción se mantiene, y además los errores en el primer paso son más pequeños, estas predicciones irán mejorando a medida que se vayan incrementado el número de datos, muestra de ello se visualiza en la Figura 76, donde se distingue la predicción de la demanda eléctrica versus su valor real después de haber estado operando el sistema 25 días y de irse almacenando las mediciones, esto se debe principalmente porque el modelo va cambiando sus parámetros ante cada entrenamiento re calculando los parámetros del modelo, y minimizando cada vez más los errores de predicción.

Al comparar el comportamiento del predictor después de veinticinco días se nota las mejoras de predicción, que mejorando a medida que más datos sean almacenados.




Figura 75 Predicción de la demanda eléctrica a 192 pasos en el primer entrenamiento del escenario 8 días




Figura 76 Predicción de la demanda eléctrica a 192 pasos al transcurrir 25 días de operación de la micro-red

En la Tabla 25, se muestra los errores MAPE, MSE y la varianza promedio de 14688 réplicas, en distintos horizontes de tiempo, destacando que los errores se incrementan en el tiempo, además de la importancia del uso del horizonte deslizante en el pre-despacho de la energía EMS. En la tabla se evalúa los errores para varios pasos de donde los errores a 192 pasos son superiores al de un paso en cualquiera de los casos, estos resultados son después de ejecutar el modelo por 25 días.

Tabla 25 Errores de predicción para el escenario 8 días

Pasos	Tiempo	MAPE [%] Durante 25 días	MSE [kW] Durante 25 días	Var [kW] Durante 25 días
4	1 hora	19.048	3.752	1.203
48	12 horas	20.321	4.347	1.627
96	1 día	20.311	4.395	1.671
192	2 días	21.945	5.131	1.948

En la Figura 77, bajo el escenario en el cual se dispone de 8 días de medición se verifica como el error MAPE decrece a medida que va aumentando las mediciones para el entrenamiento. Además en los primeros cinco días de ejecución hay presencia de errores MAPE más altos, pero después de estos los errores MAPE van decreciendo, esto en un análisis de 25 días se esperaría que este valor decrezca aún más al ampliar el horizonte de análisis. Lo mismo ocurre con el error MSE, esto se puede notar en la Figura 78, y de igual forma ocurre con la varianza que va disminuyendo con el tiempo ante nuevos entrenamientos apreciable en la Figura 79.




Figura 77 Error MAPE a 192 pasos ante modificaciones de parámetros del modelo predictor (escenario 1)




Figura 78 Error MSE a 192 pasos ante modificaciones de parámetros del modelo predictor (escenario 1)





Figura 79 Varianza del error a 192 ante modificaciones de parámetros del modelo predictor (escenario 8 días)

El error MAPE puede ir variando desde su primera ejecución de 60.530 %, a 23% después de 1244 réplicas y reduciendo aún más a 18.842%, analizando el error a 192 pasos. Mientras que si analiza a un paso que es importante porque al tratarse de horizonte deslizante cada 15 minutos los errores se reducen debido a la actualización de la predicción cada quince minutos. Los errores MAPE lograr bajarse de 38.83 % en el peor de los casos que es ante un modelo entrenado con 8 días, a 12.2% con entrenamiento de 25 días, estos resultados se muestran en la **Tabla 26**.

Tabla 26 Errores frente distintas ejecuciones de predicción tanto para un paso como para 192 pasos

# de predicción	MAPE [%]	MSE [kW]	VAR [kW]	MAPE [%]	MSE [kW]	VAR [kW]
	192 pasos	192 pasos	192 pasos	1 paso	1 paso	1 paso
1	60.530	32.708	12.771	38.830	14.983	0.751
1244	23.008	4.719	1.790	5.067	0.228	0.048
2399	18.842	3.915	1.286	12.207	1.076	0.160

En la **Figuran 80** como era de esperance se muestra como el error crece a mayores paso o crece en el tiempo de predicción, para este caso se puedo ver que entre 20 y 90 pasos el error se encuentra en una banda de variación de aproximadamente 0.05 kW, y presenta un crecimiento más significativo a partir del paso 100.



Figuran 80 Errores absolutos de predicción a pasos.

El incremento de datos para el entrenamiento trae consigo el incremento de tiempo computacional, en la Figura 81 se aprecia el número de entrenamiento que implica mayores datos, versus el tiempo en minutos, los principales cambios o aumentos en el tiempo se dan durante los primeros entrenamientos, que pese a que tienen menores datos ocupan más tiempo computacional, la justificación podría ser porque es la etapa inicial de donde se va adaptando el modelo, sin embargo no se distingue un crecimiento significativo del tiempo de entrenamiento al aumento de datos esto principalmente porque las épocas de entrenamiento son cortadas por el conjunto de validación y porque además la inicialización de los pesos y bias para cada nuevo entrenamiento son los pesos generados por el entrenamiento pasado, sin embargo este análisis es únicamente para 25 días, se esperaría un aproximado de 5 min con datos de un año.




Figura 81 Tiempos de entrenamiento al incrementar mediciones.

En las Figura 82, Figura 83, Figura 84, se muestran predicciones de demanda eléctrica versus la demanda real para un paso equivalente a 15 minutos, para 96 pasos equivalente a un día y 192 paso o dos días, respectivamente, para los tres casos las primeras predicciones presentan mayores errores.




Figura 82 Predicción de la demanda eléctrica a un paso (escenario 1)




Figura 83 Predicción de la demanda eléctrica a 96 pasos (escenario 1)




Figura 84 Predicción de la demanda eléctrica a 192 pasos (escenario 1)

6.4.2 Aplicación de la metodología para el diseño del modelo de predicción de demanda eléctrica bajo el escenario 4 meses

Este escenario considera de 4 meses de datos de mediciones, este escenario a su vez puede usarse bajo dos criterios el primero que consiste en utilizar un modelo sin entrenamiento en línea es decir identificando fuera de línea y manteniendo constantes los valores de los parámetros peso y bias, y el criterio en el que el que se parte de un modelo identificado que es el del criterio anterior pero se realiza un entrenamiento en línea es decir los pesos y bias se van actualizando ante cada entrenamiento.

La metodología usa se muestra en la figura igual que en la sección anterior con el otro escenario:

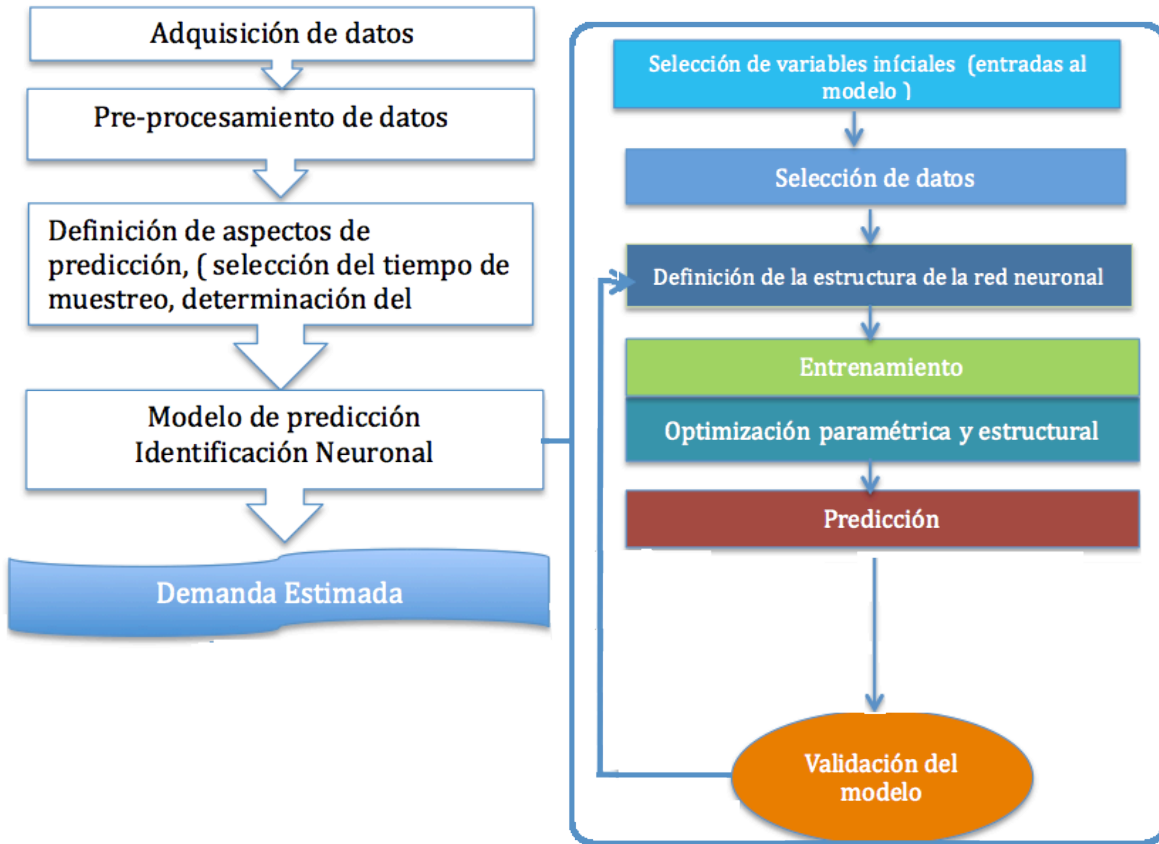


Figura 85 Metodología para identificar un modelo de predicción usado redes neuronales artificiales

Adquisición de datos.

Las mediciones recolectadas de la micro-red Huatacondo se describen en las siguientes tablas que muestran las variables climáticas como radiación solar velocidad de viento, temperatura, humedad, y de potencias como la de demanda eléctrica y solar:

Potencia solar

Desde	Hasta
02/12/2010	04/12/2010
12/12/2010	30/12/2010
01/01/2011	06/02/2011
27/02/2011	06/05/2011

Demanda eléctrica

Desde	Hasta
02/12/2010	04/12/2010
12/12/2010	09/05/2011
07/07/2011	12/07/2011

Velocidad de viento

Desde	Hasta
15/01/2011	30/03/2011
03/08/2011	26/09/2011

Radiación Solar

Desde	Hasta
22/11/2010	25/11/0210
03/12/2010	14/01/2011

Temperatura

Desde	Hasta
22/11/2010	25/11/0210
03/12/2010	14/01/2011

Pre-procesamiento de datos.

A cada grupo de datos se le realiza el pre-procesamiento

Aspectos generales que definen la predicción

Uso: Las predicciones son utilizadas como entrada del EMS para la gestión de energía en una micro-red en modo deslizante, la planificación se realiza cada 15 minutos para 2 días.

Tiempo de muestreo de las mediciones: Cada 15 minutos

Horizonte de predicción: De 48 horas (2 días, 192 puntos de medición)

Pasos de predicción: 192 pasos, equivalente a dos días.

Modelación basada en redes neuronales

1.- Selección de variables iniciales

En la Figura 86, se muestra el diagrama de dispersión entre la potencia solar y la demanda eléctrica, se distingue que no tienen alta correlación, descartando así el uso de la potencia solar para predicción de la demanda eléctrica. La constante de correlación es negativa y de valor 0.2, lo que denota que no existe relación considerable entre las dos variables.

Con respecto a correlaciones con variables climáticas, se incluyo diagramas de dispersión de la demanda eléctrica con la velocidad del viento Figura 87, además de la demanda eléctrica con la radiación solar Figura 88, también de la demanda eléctrica con la temperatura Figura 89, para cada caso los coeficientes de correlación tienen valores de 0.06, 0.25, 0.13, respectivamente, se puede notar que de acuerdo a este análisis estas variable no son altamente influyentes en la demanda eléctrica.

Hay una correlación no incluida por escasos de información que es la correlación entre la demanda eléctrica y los registradores de pulso de cada casita, que su sumatoria representa parte de la demanda eléctrica residencial, en donde se esperaría que la constante de correlación sea alta.




Figura 86 Diagrama de dispersión entre la potencia solar y la demanda eléctrica




Figura 87 Diagrama de dispersión entre la velocidad del viento y la demanda eléctrica




Figura 88 Diagrama de dispersión entre la radiación solar y la demanda eléctrica




Figura 89 Diagrama de dispersión entre temperatura y la demanda eléctrica

En la Tabla se resumen los coeficientes de correlación entre la demanda y varias variables, donde el valor de estos coeficientes son bajos, es decir que existe una dependencia muy baja de las distintas variables, concluyendo que las estaciones climáticas no son totalmente incluyentes en el consumo. En función a estos resultados se determina que la variable a usar es únicamente la demanda eléctrica pasada, se hubiera esperado que al menos la temperatura tenga influencia en la demanda eléctrica pero no ocurre esto lleva a pensar que las estaciones climáticas no son lo suficientemente marcadas para influir en el consumo eléctrico. De la Tabla 27 también se puede concluir que la potencia solar tiene lógicamente alta correlación con la radiación solar, con la temperatura, variables que deberían ser consideradas al querer predecir potencia solar, a su vez la temperatura muestra alta correlación con la potencia solar radiación y humedad que era de espesarse, de igual forma la humedad con la temperatura y radiación. Este análisis nos permite observar la influencia de todas las variables.

Tabla 27 Coeficiente de correlaciones entre variables

	Demanda	Potencia solar	Velocidad del viento	Temperatura	Radiación solar	Humedad
Demanda	1.0000	-0.2006	0.0610	-0.1303	-0.2527	0.2543
Potencia solar	-0.2479	1.0000	-0.2006	0.8058	0.9729	-0.6910
Velocidad del viento	0.0610	-0.2006	1.0000	-0.1480	-0.2542	0.2436
Temperatura	-0.1303	0.8058	-0.1480	1.0000	0.8416	-0.7902
Radiación solar	-0.2527	0.9729	-0.2542	0.8416	1.0000	-0.7159
Humedad	0.2543	-0.6910	0.2436	-0.7902	-0.7159	1.0000

En la Figura 90, se tiene una representación gráfica de la correlación de la variable de interés que es la demanda eléctrica con otras variables, la que mayor valor absoluto de coeficiente de correlación tiene es la radiación sin embargo no es lo suficientemente representativa como para ser considerada como entrada.

Este análisis a futuro en casos en que se implemente sistemas de gestión de demanda eléctrica se esperaría que las correlaciones entre las variables consideradas recursos renovables sean altas es decir ante mayor cantidad de recursos mayor uso de la energía.




Figura 90 Correlación entre variables

Una vez determinado que la variable a usar es la demanda eléctrica pasada, se analiza las correlaciones entre los meses de las mediciones disponibles, los resultados se muestran en la

Tabla 28. En sus resultados las correlaciones en general son promedios indistintamente que determinado mes pertenezcan a una estación climática común o en su defecto en meses de estaciones opuestas, por ejemplo se esperaría que Enero tenga altas correlaciones con febrero y diciembre sin embargo con febrero no ocurre, pero se manejan en márgenes de correlación medios, y se esperaría baja correlación entre enero y julio por tratarse de la estación climática opuesta es decir invierno sin embargo es de 0.5, lo propio ocurre con los otros meses, en donde las correlaciones de la demanda por meses está en el rango de 0.3 a 0.7 lo que nos lleva a concluir que las estaciones climáticas no son tan significativos en la demanda eléctrico.

Tabla 28 Correlación de la demanda eléctrica entre meses

	ENERO	FEBRERO	MARZO	ABRIL	MAYO	JULIO	DICIEMBRE
ENERO	1.0000	0.3864	0.3585	0.5650	0.4086	0.5419	0.6697
FEBRERO	0.3864	1.0000	0.3427	0.5083	0.4594	0.4816	0.4271
MARZO	0.3585	0.3427	1.0000	0.4657	0.4855	0.5241	0.3790
ABRIL	0.5650	0.5083	0.4657	1.0000	0.4945	0.5708	0.6077
MAYO	0.4086	0.4594	0.4855	0.4945	1.0000	0.6824	0.4107
JULIO	0.5419	0.4816	0.5241	0.5708	0.6824	1.0000	0.5181
DICIEMBRE	0.6697	0.4271	0.3790	0.6077	0.4107	0.5181	1.0000

Luego del análisis por meses se realiza un estudio de correlación por días de las semanas. Estos resultados se muestran en la Tabla, destacando que la correlación entre días similares es superior a 0.5 lo que permite

definir que los días similares son influyentes es decir si quiere predecir un día lunes se puede utilizar de referencia los lunes de semanas pasadas.

En la figura se muestra los histogramas obtenidos de analizar las correlaciones por días destacando que la mayoría de coeficientes supera a 0.5, en algunos más como es el caso del día martes, jueves y viernes, aseverando los resultados anteriores de la Tabla.

Tabla 29 Correlación por días de la demanda eléctrica

	Lunes	Martes	Miércoles	Jueves	Viernes	Sábados	Domingos
Correlación	0.6555	0.5575	0.6276	0.6189	0.5654	0.5941	0.5833

Tabla 30 Histogramas de la correlación entre días similares de la semana

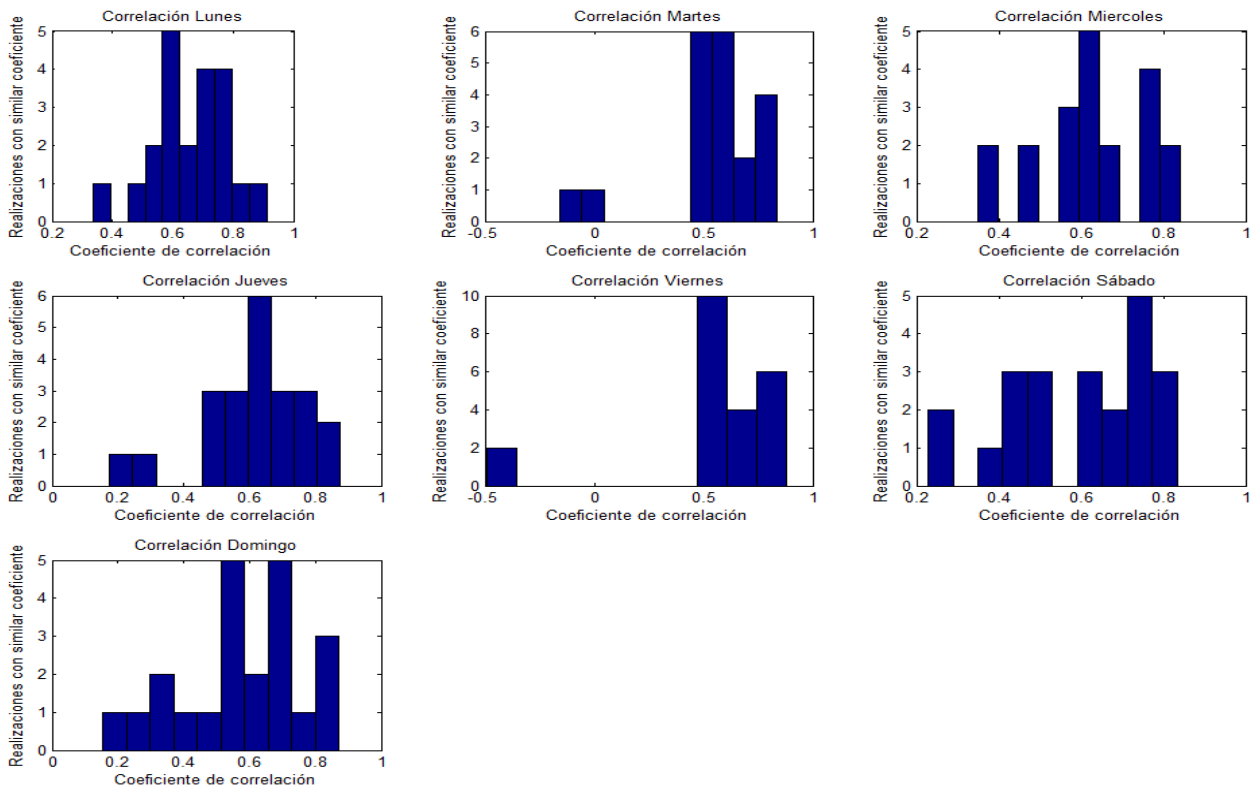


Figura 91 Histogramas de la correlación entre días similares de la semana de la demanda eléctrica

Como entrada inicial se puede considerar días similares. Se realiza también un análisis de correlaciones por periodos pasados es decir regresares o equivalentes a 15 minutos para lo cual se toma un tiempo t y se analizan correlaciones con tiempos pasados y futuros de la demanda eléctrica, para poder distinguir qué valores de t pasados influyen en la demanda en el tiempo t.

En la Figura 92, se resume los promedios de las correlaciones de la demanda de un tiempo t con distintos regresores en el tiempo, en función a esto se determina los regresores más influyentes y a considerar son los incluidos en la tablas que equivalen un día pasado.




Figura 92 Regresores influyentes en la demanda eléctrica

Del análisis de correlación de las variables radiación, velocidad de viento, demanda eléctrica se determina como entradas antes de la optimización del modelo los regresores de la Tabla 31, y su equivalente en el tiempo de la demanda eléctrica que pueden ser futuras entradas del modelo de predicción. Donde y es la demanda eléctrica.

Tabla 31 Entradas iniciales para el modelo de predicción de demanda eléctrica a corto plazo en micro-redes

	Representación en el tiempo	Regresores
Regresores pasados	1 día pasado	$y(t-1), y(t-2), y(t-3), \dots, y(t-96)$
Mismo día de la semana pasada	En el tiempo (t)	$y(t-672)$
Mismo día de la semana pasada	5 horas antes a (t)	$y(t-671), y(t-670), y(t-669), \dots, y(t-651)$
Mismo día de la semana pasada	5 horas después a (t)	$y(t-673), y(t-674), y(t-675), \dots, y(t-693)$

2.- Selección de datos

En los s previos se determino las variables que se usarán inicialmente y se determinó la demanda eléctrica pasada, debido a que las otras variables tenía una correlación más débil. Además se identificó las entradas es decir sus regresores más importantes a usar como entradas del modelo. Para el caso de Huatacondo de acuerdo a los datos de medición disponibles se distribuyeron como se muestra en la Tabla 32.

Tabla 32 Porcentajes de datos

	Porcentaje	Número de datos	Desde	Hasta
Datos de entrenamiento	60	8985	02/12/2010	14/03/2011
Datos de test	30	4493	14/03/2011	30/04/2011
Datos de validación	10	1498	30/04/2011	12/07/2011

3.- Definición de la estructura inicial de la red neuronal

Se parte de una estructura inicial basada en las entradas de la Tabla 31 y en función a esta estructura se buscara ir optimizando hasta obtener una estructura óptima.

Tabla 33 Estructura inicial de la red neuronal

Estructura inicial de la red neuronal	
Número de capas	3
Número de capas ocultas	1
Neuronas de la capa de entrada o entradas del modelo	192
Neuronas de la capa oculta	12
Neuronas de la capa de salida	1
Función de activación de la capa oculta	Tansig
Función de activación de la capa de salida	Purelin
Entrenamiento	Backpropagation
Tipo	Supervisado

4.- Entrenamiento

Dos criterios uno entrenamiento fuera de línea, y el criterio dos entrenamiento en línea cada 2 días.

5.- Optimización de estructura

Se parte de la entradas establecidas en la Tabla 31, y se van eliminando una a una las entradas, se entrenan y se obtiene los parámetros se estima y determina los errores, y así sucesivamente estos errores son comparados y de ellos se selecciona el de menor valor, de la misma forma se procede a modificar las neuronas de la capa oculta y obtener errores de predicción, al comparar todos los errores los de menor valor son aquellos que definen la mejor estructura. Como el uso es para un EMS, se analiza distintos horizontes de tiempo es decir a una hora, un día y dos días. La mejor estructura del modelo neuronal considerado tiene las siguientes características.

Tabla 34 Estructura optimizada de la red neuronal

Estructura óptima de la red neuronal	
Número de capas	3
Número de capas ocultas	1
Neuronas de la capa de entrada o entradas del modelo	96
Neuronas de la capa oculta	8
Neuronas de la capa de salida	1
Función de activación de la capa oculta	Tansig
Función de activación de la capa de salida	Purelin
Entrenamiento	Backpropagation
Tipo	Supervisado

Resultados de predicción del modelo predictor de demanda eléctrica bajo el escenario de 4 meses

En la Figura 93, se muestra la demanda eléctrica medida. Se puede distinguir la presencia de cambios en los perfiles donde hay potencia de demanda máximas.




Figura 93 Medición de la demanda eléctrica

La validación del modelo de predicción utiliza los datos diferentes, de la que incorpora las diversas variabilidades presentes en la demanda a de Huatacondo, para validar su comportamiento.

En la Tabla 35, se muestran los errores MAPE, MSE y varianza para el escenario de 4 meses, considerando que no se realiza un entrenamiento en línea. En este caso por contar con mediciones se tiene la posibilidad de realizar la selección de un modelo con estructura óptima, los errores no decrecen sino más bien se mantienen, a diferencia del escenario de 8 días se puede notar que los errores en las primeras ejecuciones son elevados, mientras que en este escenario no, sin embargo al tratarse de un modelo estático los pesos no cambian, si en los seis meses restantes que no se cuenta con información se produjeran cambios en la demanda el modelo fijo no tiene la capacidad de adaptarse y aprende de estas variaciones, se pueden incrementar los errores. Se puede observar los errores llegan hasta 15% para 192 pasos, que es en todo caso inferior al de las primeras ejecuciones del escenario anterior.

En la Figura 95, se visualiza el MAPE, con presencia de una zona en donde el error se incrementa. Esta zona es cuando hubo presencia de un incremento de la demanda eléctrica. Las zonas donde menores son los errores son porque el perfil de demanda presente en esa zona es más repetitivo o común en los datos usados para el entrenamiento, mientras que donde se produce los errores mayores es porque menor presencia de casos similares hubo. De ahí la importancia de tener la mayor cantidad de datos pero variada, es decir ricos en información sin embargo la mayor parte de los errores oscila entre el 11 y 14 %.




Figura 94 Datos de validación del modelo de predicción

Tabla 35 Errores de predicción para el segundo escenario

Pasos	Tiempo	MAPE [%]	MSE [kW]	VAR [kW]
4	1 hora	13.615	1.943	1.450
48	12 horas	14.339	2.157	1.922
96	1 día	14.224	2.139	1.967
192	2 días	14.595	2.291	2.106

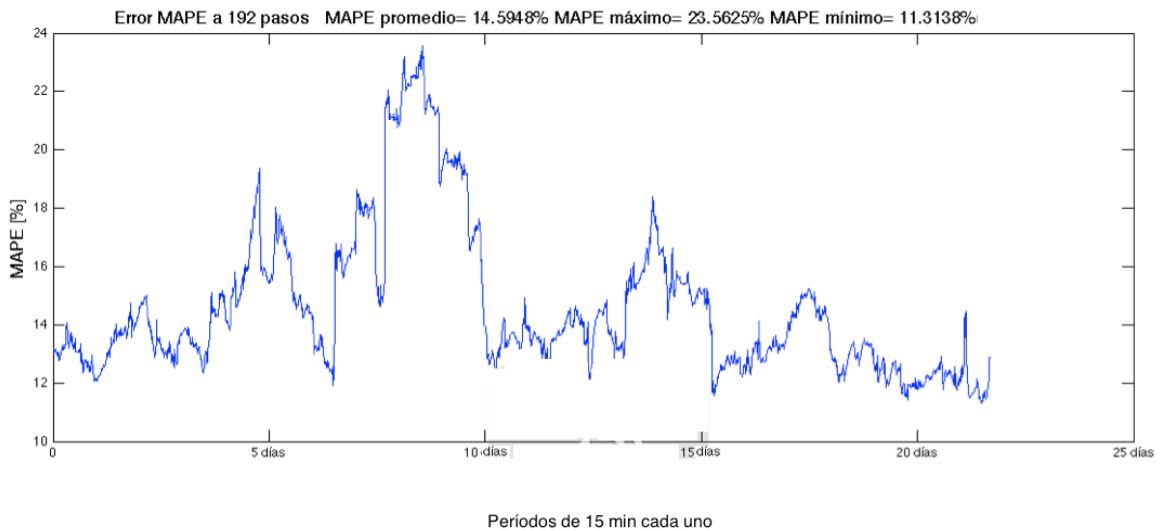


Figura 95 Error MAPE a 192 pasos (escenario 2)

En las figura Figura 96 y Figura 97, se observa el mismo efecto, para los indicadores MSE y su varianza, que ante cambios que no fueron suficientemente entrenados por falta de eventos similares en los datos, crece el error, lo contrario ocurre en cambio si la serie a predecir es similar al perfil que más datos similares incluyo en el entrenamiento ante eventos, así los errores disminuyen.




Figura 96 Error MSE a 192 pasos (escenario 2)

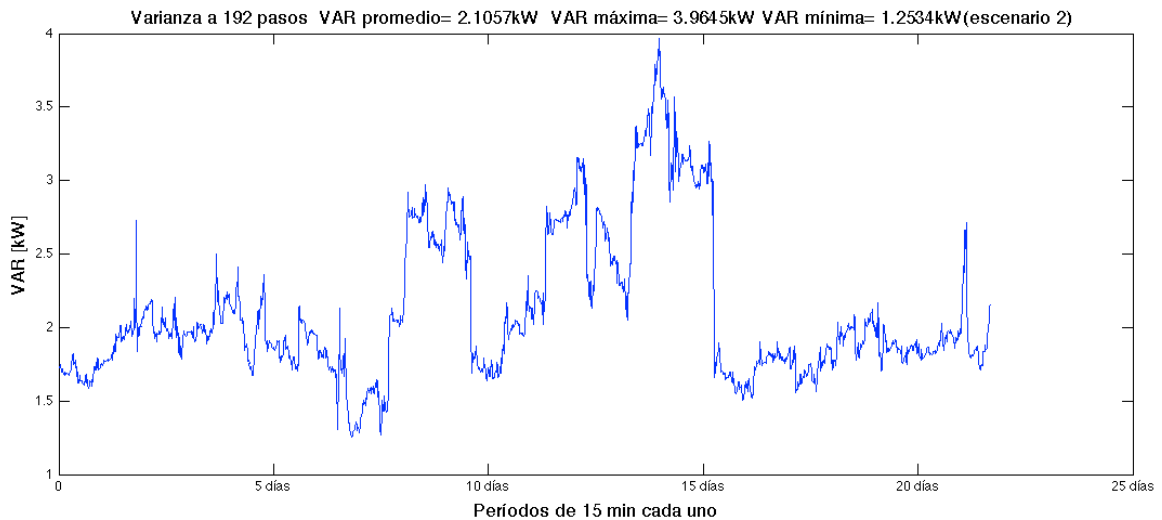


Figura 97 Varianza del error a 192 (escenario 2)

En la Figura 98 se visualiza la predicción de la demanda eléctrica versus el valor real, con un MAPE del 11%. Se puede notar que la predicción se aproxima al valor real, excepto en determinados incrementos que aparentemente serían inesperados, esto principalmente se debe a que cada cambio mínimo en el consumo se puede reflejar como una perturbación porque los consumos son pequeños y el encendido de un electrodoméstico ya es una variación en la demanda total. La Figura 99 en cambio muestra una de las peores predicciones que muestra el modelo en este periodo de veinte cinco días de análisis, en el paso 40 y 115 se distingue unos bajones inesperados de la serie medida, este efecto puede ser producido por

mediciones equivocadas, incrementando el error en estos puntos y con ello el crecimiento del MAPE a un 23%.




Figura 98 Predicción de la demanda eléctrica a 192 pasos (escenario 2)




Figura 99 Predicción de la demanda eléctrica a 192 (escenario 2)

La Figura 100, muestra el crecimiento del error ante mayor número de pasos y como era de esperarse el error es menor en los primeros pasos.

La Figura 101, Figura 102, y Figura 103 describe la predicción a un paso, a 96 pasos y 192 pasos respectivamente de estas predicciones se nota que el modelo sigue las señales y es en las zonas de la serie donde se produce los bajones más fuertes, y consumos más altos donde el predictor tiene mayor dificultad de predecir, sin embargo la tendencia la mantiene.




Figura 100 Error absoluto promedio de predicción por paso de predicción (escenario dos)

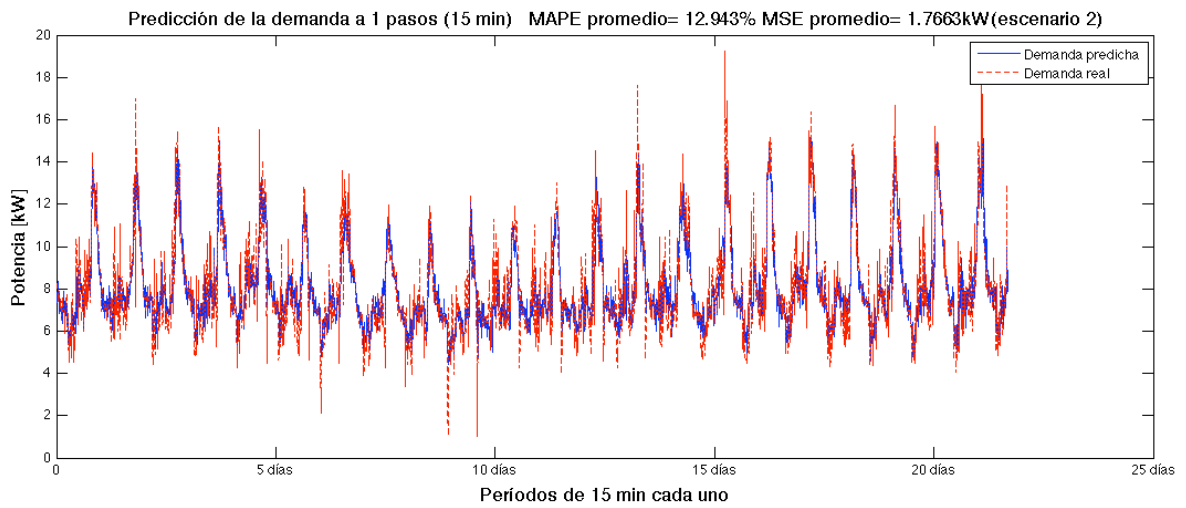


Figura 101 Predicción de la demanda eléctrica a un paso (escenario 2)




Figura 102 Predicción de la demanda eléctrica a 96 pasos (escenario 2)




Figura 103 Predicción de la demanda eléctrica a 192 pasos (escenario 2)

El tiempo computacional usado para este entrenamiento es de 0.4 minutos. Este modelo que es considerado el óptimo es el punto de partida para el uso del modelo con entrenamiento en línea descrito a continuación. La identificación de parámetros del modelo se usa para la primera predicción hasta tener una nueva estructura frente el siguiente entrenamiento.

Horizonte deslizante:

El modelo anterior es usado como estructura inicial del modelo de predicción con entrenamiento en línea bajo el escenario dos, el entrenamiento es realizado cada dos días. El hecho de usar el modelo óptimo como modelo inicial reduce el error en la primera estimación, en la Tabla, se muestran los indicadores MAPE y MSE y varianza a 4, 48, 96, y 192 pasos.

Tabla 36 Errores de predicción para el segundo escenario con entrenamiento en línea

Pasos	Tiempo	MAPE [%]	MSE [kW]	VAR [kW]
4	1 hora	12.851	1.811	1.379
48	12 horas	13.712	2.100	1.891
96	1 día	13.810	2.153	2.029
192	2 días	14.495	2.469	2.322

La Figura 104, muestra la primera predicción de la demanda eléctrica a diferencia del escenario anterior, el MAPE de la primera estimación no cuenta con MAPE altos esto principalmente porque el modelo inicial es un modelo que ya fue optimizado, y es usado para estimar por dos días hasta que se realice la nueva predicción de la demanda.

Se incluyo la Figura 105 donde los errores de predicción son de menor valor, se pudo notar que las predicción se parece al valor real, y los errores son producidos por la alta variabilidad de la demanda




Figura 104 Predicción de la demanda eléctrica ante el primer entrenamiento en el escenario dos con entrenamiento en línea




Figura 105 Predicción de la demanda eléctrica con error de MAPE del 10.26% en el escenario

También se incluyó la Figura, que presenta errores de predicción más altos, y se puede notar que los errores más significativos se producen cuando intenta predecir demandas que presentaron alguna variación significativa como por ejemplo predecir demandas que inesperadamente bajan el valor esto puede ser producto de mediciones erradas, además son perfiles que su peak de demanda tienen valores de 12 kW, inferiores a los que normalmente se tiene, por eso la importancia de entrenar con un mayor número de datos y diferentes, al incluir más datos de este tipo los errores disminuirán.

Predicción de la demanda a 192 pasos (horizonte de dos días) MAPE = 20.6194% MSE = 3.1678kW VAR = 2.5056kW(escenario 2 con entrenamiento en línea)




Figura 106 Predicción de la demanda eléctrica con altos errores de predicción en el escenario dos con entrenamiento e línea.

El error MAPE, a 192 pasos, promediado de 19 días, es de 14.495%, en la Figura 107, se distingue zonas en donde se incrementa estos errores específicamente del cuarto al sexto día o en el onceavo día, esto ocurre porque los datos utilizados para validar Figura 94, son variados justamente para evaluar bajo distintos tipos de perfiles y cambios bruscos.

Error MAPE a 192 pasos MAPE promedio= 14.495% MAPE máximo= 21.0533% MAPE mínimo= 10.2691%(escenario 2 con entrenamiento en línea)




Figura 107 Error MAPE a 192 pasos promedio de 19 días en el escenario dos con entrenamiento en línea.

La Figura 108, muestra el MSE al usar entrenamiento en línea y como era de esperarse se produce el mismo efecto que en MAPE en los días con alteraciones muy significativas de la demanda, es caso similar con la varianza a 192 pasos, promediados de 19 días, en la Figura 109




Figura 108 Error MSE a 192 pasos de 19 días el escenario dos con entrenamiento en línea




Figura 109 Varianza del error a 192 pasos en el escenario dos con entrenamiento en línea.

El error de predicción promedio de 19 días, va creciendo en el tiempo es decir aumenta con el incremento de paso es así que si se considera predicciones menores a 100 pasos se obtienen errores inferiores a 1.1 kW, la Figura muestra el incremento del error en el tiempo, y valida el uso de pre-despacho en modo deslizante de esta forma utiliza entradas con menores errores de predicción.




Figura 110 error absoluto a 192 paso promedio de 19 días frente al escenario dos con entrenamiento en línea

Uno de los aspectos preocupantes es el tiempo de entrenamiento ante mayor número de datos. La Figura 111 muestra los tiempos usados en entrenamiento, los cuales aumentan con el número de datos. En validación se considero un máximo de datos de 12468, equivalente a cuatro meses y medio, y el máximo tiempo registrado fue inferior a 12 minutos, este es un aspecto importante para valorar cada cuanto se realiza el entrenamiento el modelo tiene la facilidad de seleccionar cada cuanto se realiza el entrenamiento es decir la identificación de los parámetros del modelo neuronal.




Figura 111 Tiempo de entrenamiento frente al escenario dos con entrenamiento en línea

La Figura 112, Figura 113, Figura 114, muestran la predicción de la demanda eléctrica a un paso, 96 pasos equivalente a un día, y a 192 datos dos días, respectivamente. Se distingue que las predicciones es similar a la demanda original y como es de esperarse a un paso los errores son menores con MAPE promedio de 12.1% MSE 1.6 kW, mientras que a 96 pasos se incrementa a 13,8 % y 2.1kW. Se puede notar que el error a 196 pasos es mayor en un valor de 14.4 % MAPE promedio, si se utiliza predicciones a menores pasos se garantiza mejor predicciones.




Figura 112 Predicción de la demanda eléctrica a un paso

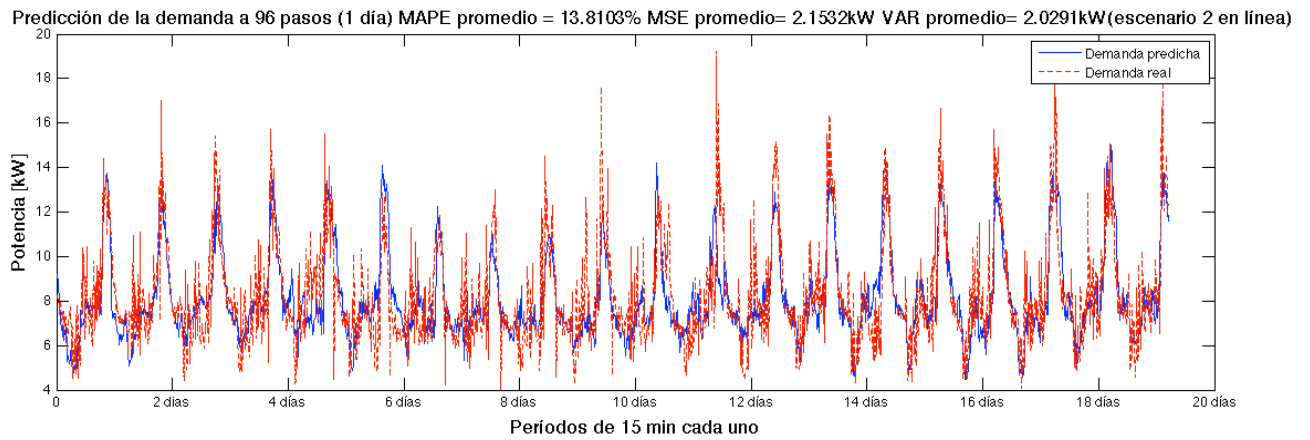


Figura 113 Predicción de la demanda eléctrica a 96 pasos




Figura 114 Predicción de la demanda a 192 pasos

Análisis comparativo

En la Tabla, se incluye los errores MAPE, MSE y varianza frente a los dos escenarios evaluados a cuatro pasos. Se distingue que los errores son mayores en el escenario uno que empezó esto es principalmente porque las primeras predicciones con entrenamiento de apenas 8 días son altos, mientras que al incrementar el tiempo de funcionamiento es decir mayores datos en línea va mejorando la predicción, el error incluido es un error promedio desde la primera predicción hasta la 2399 predicción, frente a cuatro paso es menor el error en escenario dos con entrenamiento en línea.

En la Tabla 38 en cambio se analiza los errores a 48 pasos en donde el MAPE decrece, al igual que la varianza y el MSE.

En la Tabla 39 se verifica el mismo efecto donde el modelo se comporta mejor frente a mayor número de datos para el entrenamiento.

Tabla 37 Errores de predicción a cuatro paso en escenario uno y dos

	Entrenamiento en línea	Pasos	Pasos en tiempo	MAPE [%]	MSE [kW]	Var [kW]
Escenario 1	2 horas	4	1 hora	19.048	3.752	1.203
Escenario 2	sin	4	1 hora	13.615	1.943	1.45
Escenario 2	2 días	4	1 hora	12.851	1.811	1.379

Tabla 38 Errores de predicción a 48 paso bajos los dos escenarios.

	Entrenamiento en línea	Pasos	Pasos en tiempo	MAPE [%]	MSE [kW]	Var [kW]
Escenario 1	2 horas	48	12 horas	20.321	4.347	1.627
Escenario 2	sin	48	12 horas	14.339	2.157	1.922
Escenario 2	2 días	48	12 horas	13.712	2.1	1.891

Tabla 39 Errores de predicción de la demanda eléctrica a 96 pasos bajo los dos escenarios.

	Entrenamiento en línea	Pasos	Pasos en tiempo	MAPE [%]	MSE [kW]	VAR [kW]
Escenario 1	2 horas	96	1 día	20.311	4.395	1.671
Escenario 2	sin	96	1 día	14.224	2.139	1.967
Escenario 2	2 días	96	1 día	13.81	2.153	2.029

En la Tabla 40, se comparan los errores frente a los dos escenarios, se distingue que el error decrece pero no es tan significativo entre usar un modelo entrenado fuera de línea que uno entrenado cada dos días en línea, para el escenario uno muestra un error superior de 20 % esto porque se están promediando los errores y los primero errores presentan altos valores mientras que después de unos días de ejecución este error va disminuyendo llegando a valores del 10%, efecto similar ocurre con el error MSE y con la varianza.

Tabla 40 Errores de predicción de la demanda eléctrica a 192 pasos bajo dos escenarios

	Entrenamiento en línea	Pasos	Tiempo	MAPE [%]	MSE [kW]	VAR de MSE [kW]
Escenario 1	2 horas	192	2 días	21.945	5.131	1.948
Escenario 2	Sin	192	2 días	14.595	2.291	2.106
Escenario 2	2 días	192	2 días	14.495	2.469	2.322

6.5 Modelo de predicción de demanda a corto plazo propuesto sin validar

Para mejorar los errores de predicción de demanda eléctrica a corto plazo se propone un modelo Figura 115, que a diferencia del modelo validado anteriormente se incluye una entrada extra proveniente de la medición en línea de la demanda eléctrica en ciertas casas donde se colocaron registradores de pulsos. Además frente a la gran variabilidad de las mediciones una opción es utilizar transformadas wavelets, como una etapa de pre-procesamiento de datos, separando las señales en alta y baja frecuencia, a la propuesta anterior se incorpora transformadas wavelets como se muestra en la Figura, realizando la predicción en alta y baja frecuencia y al final sumando las dos, para obtener la predicción final de la demanda. La técnica de predicción es la misma con redes neuronales pero ahora el filtro que de alguna forma ayudara a la alta variabilidad de las señales y consideran una nueva entrada a la red neuronal.

Este modelo podrá ser validado al disponer de mediciones de los registradores de pulso de las casas, se espera que la predicción mejore ya que el modelo actual no incluye otras entradas a parte de la demanda pasada, después de hacer un análisis de correlaciones ninguna otra era altamente influyente en la demanda eléctrica, mientras las mediciones de los registradores de pulso se espera y tenga un correlación alta, ya que representa parte de la demanda residencial de influencia en la demanda total de la comunidad.

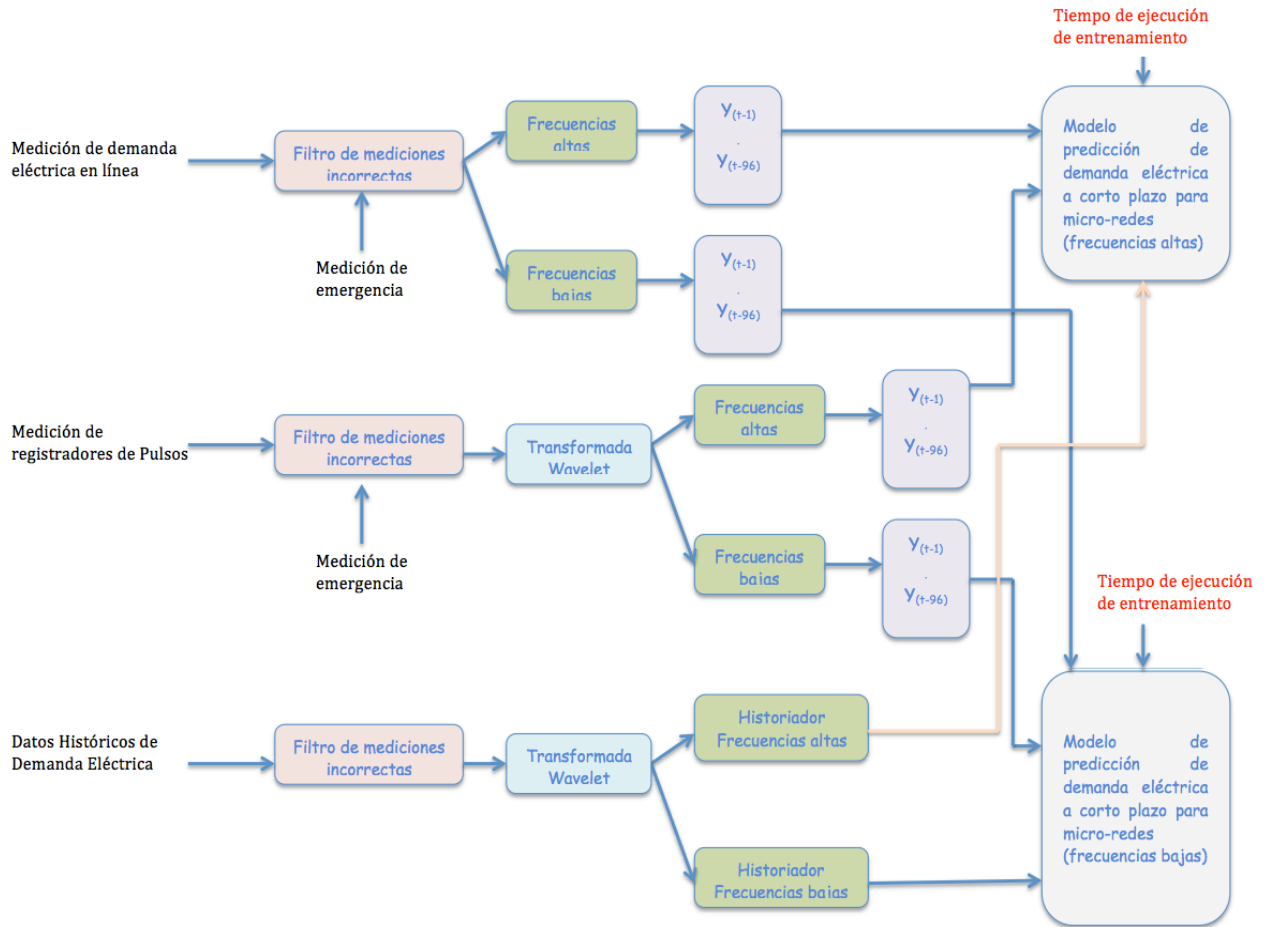


Figura 115 Propuesta por valida del modelo predictor de demanda en micro-redes

Una característica importante de las micro-redes es la capacidad de realizar gestión de la demandada eléctrica, bajo este criterio se plantea la necesidad de un modelo para la predicción de la demanda eléctrica a corto plazo consideran un plan de gestión de la demanda.

La gestión de demanda consiste en recorrer los consumos de horario punta a la zona valle del perfil diario de la demanda.

El optimizador de la gestión de la energía tiene incorporado una aplicación de gestión de demanda que consiste en enviar señales de uso de la energía en el tiempo, señales que son enviadas a un dispositivo de control, que físicamente es similar a un reloj.

La planificación horaria es por medio de indicadores luminosos parecidos al de un semáforo que pueden adquirir colores verde que representa consumo de energía, amarillo que significa evitar consumir energía, y el rojo no consumir energía. El indicador que se coloca en la casas de los usuarios de la energía tiene forma de reloj resaltando las veinticuatro horas del día como se muestra en la Figura 116, además en cada hora hay un indicador luminoso así el usuario sabrá como usar la energía



Figura 116 Dispositivo de control d demanda

Las señales de encendido de las luces son generadas por el optimizador del MSE, bajo el siguiente criterio:

$$P_L(t) = S_L(t)P_L(t)$$

Donde P es la carga esperada P , y la señal de movimiento de la demanda está definida por:

$$S_{Lmin}(t) \leq S_L(t) \leq S_{Lmax}(t)$$

6.6 Discusión

En este capítulo se plantea y evalúa un modelo predicción de demanda a corto plazo para micro-redes. Es un modelo basado en redes neuronales con entrenamiento en línea, que cuenta con noventa y dos entradas que representa un día pasado de demanda muestreada cada quince minutos, tiene una capa de entrada con 92 neuronas una capa oculta con 8 neuronas y una capa de salida con la predicción de la demanda en un horizonte de dos días muestreados cada quince minutos, esta demanda estimada ingresa al EMS de la micro-red, para la gestión de la energía. El modelo propuesto cuenta con una entrada que define cada cuanto se quiere realizar el entrenamiento en línea, esto dependerá del número de mediciones que se dispone. Además se alimenta de mediciones en línea.

El diseño del modelo de predicción, parte de la adquisición de datos, es decir todas las mediciones disponibles en caso de tenerlas, luego se pre-procesa los datos, posteriormente se definen aspectos importantes como: tiempo de muestreo, horizonte de predicción, pasos de predicción. Seguido se efectúa la identificación neuronal, y finalmente se obtiene la predicción de la demanda. La identificación neuronal a su vez parte de la selección de las variables iniciales, se utiliza análisis de correlación, después la selección de datos que es la división de los datos en tres grupos de entrenamiento, test y validación, se define una estructura inicial en base a la cual se va modificando hasta determinar el mejor modelo para esto se utilizo prueba y error, con una estructura óptima definida se tiene la salida la predicción.

El modelo propuesto es evaluado en dos escenarios, uno cuando la micro-red, empieza su operación y se cuenta con medición de ocho días, y el segundo cuando tiene aproximadamente 4 meses de operación. Para el primer escenario por contar con datos de medición de únicamente ocho días se escoge un

entrenamiento de cada seis horas equivalente a 24 periodos para que se vaya reajustando los parámetros del modelo a medida que tienen nuevas mediciones es decir cada que 24 datos, el comportamiento del modelo en el primer escenario dentro de los 5 primeros días presenta errores MAPE a 192 pasos de entre 20 y 60 % , equivalentes a 10 a 30kW de MSE, haciéndole que el modelo durante los cinco primeros días no sea confiable, los errores van disminuyendo a medida que cuenta con más datos, entre el quinto y décimo día, los errores disminuyen a valores que están entre el 20 y 15 %, y después de este tiempo van decreciendo dentro de los 25 días analizado el error llego a tomar valores de entre 11 y 13 % equivalente a valores menores a 4kW de MSE, verificando que con mayor datos el modelo se va reentrenando y ajustando mejor disminuyendo los errores de predicción.

En lo que respecta al segundo escenario el proceso de identificación neuronal se lo hace con más datos, y se determina el modelo óptimo con el que se inicializa las predicciones, para este escenario se puede utilizar el entrenamiento el línea cada día, dos días, una semana, etc., e incluso sin entrenamiento en línea solo usando el modelo determinado como óptimo en la etapa inicial. Se realiza pruebas y se determina que el tiempo más adecuado de realizar el entrenamiento dentro de los evaluados es cada dos horas, el entrenamiento utiliza inicialización de peso y son asignados los obtenidos por el modelo óptimo fuera de línea.

Los datos con los cuales se realiza la validación son totalmente variados esto para validar el comportamiento ante cambios bruscos de perfiles, o presencias de variaciones tanto en la zona valle del perfil, como en la demanda máxima. Es justamente frente a cambios bruscos donde los errores se incrementan llegando a tener valores de 18 a 20 % de MAPE o entre 4 y 5 kW de MSE, que serían los peores caso. Efecto contrario ocurre cuando se intenta predecir demandas que son tan variantes entre días pero no tan significativas, esto con respecto al escenario dos y al escenario uno después de ejecutarse 15 días.

Lo ideal sería contar con medición de un año y a partir de eso evaluar el comportamiento, los errores que muestran muchos trabajos son relacionados a predicciones de demanda eléctrica de ciudades que manejan potencia de consumo más elevado que las de la localidad de Huatacondo y con menos variabilidad. En una micro-redes el encendido de un electrodoméstico puede ser influyente en el perfil total. En el trabajo donde aplican a una micro-red, los errores MAPE que manejan son del 7 al 9% destacando que las potencias son superiores a los de Huatacondo, que llegan hasta el orden de los 10 MW.

En este capítulo se incluyen modelos propuesto por validar que mejorarían la predicción de la demanda al incorporar como entrada mediciones de demandada en ciertas casas que representaría una parte de la demanda residencial, que es altamente influyente en el perfil de demanda total de la comunidad. Para la adquisición de estas mediciones se sugiere que primero se identifique las casas con mayor consumo, para colocar en ellas los instrumentos de medición, debido a que esas casas son las de mayor incidencia en la demanda residencial. Además se incorpora un modelo propuesto para la predicción de la demanda eléctrica al contar con sistemas de gestión de demanda.

CAPÍTULO 7

CONCLUSIONES, APORTES Y LÍNEAS DE FUTUROS DESARROLLOS

En este capítulo final de la tesis se presentarán en primer lugar las conclusiones del trabajo de tesis realizado. Posteriormente se enuncian los aportes y finalmente se exponen algunas líneas de futuros desarrollos que han quedado abiertas a partir del trabajo desarrollado.

7.1 Conclusiones

En este trabajo de tesis se aborda principalmente dos etapas, primero la generación de perfiles diarios de demanda proyectados a la disposición de energía permanentemente en el día. Además en la segunda etapa se aborda técnicas de predicción de demanda eléctrica a corto plazo, para el diseño de modelos de predicción en micro-redes.

En la primera etapa se plantea un método para generar dos perfiles diarios aproximados de la demanda eléctrica. Un perfil que corresponde a una demanda futura considerando que la comunidad cuenta con energía las veinticuatro horas del día, mientras que el otro perfil generado es considerando días festivos, es decir con incremento temporal de población. Estos perfiles son usados en la etapa inicial de proyectos de energización en comunidades, para dimensionar las unidades de generación.

El método propuesto para generar perfiles de demanda, busca resolver el problema inicial en el diseño de las micro-redes en comunidades, donde no se cuenta con un perfil de demanda diario considerando que la localidad cuenta con energía ininterrumpida, perfil que es distinto al que originalmente tiene el pueblo con energía por ciertas horas.

Bajo estas circunstancias, la solución más adecuada consiste en caracterizar el consumo de la energía de los usuarios a partir del uso de encuestas generales de la localidad e individuales a cada casa de la comunidad que sean suficientemente representativas del comportamiento de los usuarios de la energía.

La solución propuesta para generar los perfiles está basada en un método que incluye un modelo que interactúa entre las entradas y varios módulos, para la obtención del modelo se planteó un método

secuencial. Se destaca como módulos más importantes: módulo de entradas, módulo de clasificación, módulo de búsqueda y la base de datos.

El módulo de entradas es producto de las encuestas aplicadas a la comunidad. Se determino que mediante encuestas se puede caracterizar al consumo eléctrico de la comunidad, las encuestas deben incluir preguntas que incorporen el comportamiento futuro, como por ejemplo distinguir qué tipo de electrodomésticos pretenderían comprar, que cosas ellos podrían hacer con la disponibilidad de energía eléctrica las veinte cuatro horas del día.

Un aspecto importante es el uso de un mapa Auto-organizativo de Kohonen (SOM), para clasificar tipos de familias. Esta clasificación permite la agrupación de los mismos tipos de familias atendiendo a criterios como; laborales, edades, económicos, etc. SOM ofrece una elevada capacidad para clasificar conjuntos de patrones complejos, esto se debe a que cada familia no es clasificada tan sólo por una neurona, sino más bien por un conjunto de éstas, lo cual proporciona mayor flexibilidad en los patrones pertenecientes a una misma familia.

El módulo de clasificación necesita de una base de datos, creada por mediciones obtenidas en comunidades aisladas. La base de datos es totalmente flexible de tal forma que puede incrementarse los perfiles de acuerdo a los nuevos tipos de familia que aparezcan.

Este modelo de generación de perfiles de demanda fue probado en la localidad de Huatacondo obteniendo perfiles que se aproximan al que se obtuvo después de operar la micro-red, se espera que a futuro mejoren los resultados, al contar con un modulo de base de datos mejorado con más mediciones reales.

En este trabajo de tesis también se plantea un modelo para la predicción de la demanda eléctrica a corto plazo, con un horizonte de dos días, muestreados cada quince minutos, con mediciones en línea. Este modelo está especialmente dirigido al uso en EMS de micro-redes, en operación isla. Los principales inconvenientes son que la micro-red está empezando a operar por lo que no se cuenta con datos históricos de mediciones, además que son señales bastante estocásticos por tratarse de sistemas más pequeños a los tradicionales, en donde el comportamiento de un usuario tiene impacto en el perfil total de la demanda eléctrica, diferente a sistemas tradicionales donde estos cambios no son significativos en el total de la demanda.

Bajo estas condiciones se plantea el uso de modelos con redes neuronales con entrenamiento en línea para predicción de la demanda eléctrica. Esta solución es propuesta por su capacidad de ser aproximadores universales y por su tratamiento con las no linealidades con un entrenamiento supervisado en línea, que va actualizando sus parámetros a medida que va obteniendo mayores mediciones. El modelo inicial de predicción se obtiene fuera de línea, de ahí en adelante la estructura variara con cada entrenamiento. Se observa menores tiempos computacionales de entrenamiento al utilizar pesos de inicialización de los modelos que fueron entrenados por última vez.

Para la evaluación del modelo se plantearon dos escenarios: uno con poco datos, apenas ocho días de iniciar la micro red su funcionamiento, y otro con cuatro meses de mediciones, ambos evaluados en 25 días de ejecución. Los resultados muestran que mientras mayores datos se tienen para entrenar los errores

MAPE, MSE, mejoran. Las aplicaciones bajo los dos escenarios en casos reales muestran flexibilidad, ante cada escenario se puede definir cada qué tiempo se realiza el entrenamiento. Como se esperaba al comparar la predicción con modelos lineales se verifica mejores resultados al usar redes neuronales artificiales.

Para los dos desarrollos se aborda técnicas de inteligencia computacional. En la primera aplicación para la generación de perfiles de demanda, se usa mapas auto-organizativos de Kohonen para clasificación de usuarios de la demanda eléctrica de la comunidad, mientras que en la segunda aplicación, las redes neuronales perceptron multicapa son usadas en la predicción de demanda.

7.2 Aportes

Los principales aportes de esta tesis es haber contribuido con un modelo que genera un perfil aproximado de la demanda eléctrica para cualquier tipo de comunidad aislada, suponiendo que se dispone de energía las veinticuatro horas del día, cuando no se tiene ninguna medición. Además de incluir a la comunidad a través de las encuestas, para considerar alteraciones en el comportamiento del uso de la energía ante el cambio existente de disponer de energía limitada a cierto número de horas a contar con energía ininterrumpida.

Al considerar la predicción de la demanda para micro-redes, el principal aporte se genera un análisis con respecto a la escasa disponibilidad de datos, y además las señales a predecir son altamente variantes distinto a sistemas tradicionales. La mayoría de trabajos consideran únicamente a sistemas tradicionales, casi no se analiza predicción de demanda en micro-redes. Un aporte significativo es que el modelo de predicción está implementado y funcionando en la micro-red real situada en Hutacondo.

7.3 Líneas de futuros desarrollos

A continuación se presentan las principales líneas de desarrollo que han quedado abiertas en esta tesis:

La integración de mediciones reales a la base de datos del modelo de generación de perfiles. Con esto se esperaría mejoren los perfiles generados. Además para validar la generalidad del modelo es necesario que se siga validando con otras comunidades.

Dado que la validación de este trabajo partió de encuestas ya realizadas, se podría realizar una re-validación del modelo en Huatacondo considerando en las encuestas los siguiente aspectos: base de datos real, incluir aspectos en la encuestas individuales como; electrodomésticos que se pretende adquirir en futuro, horarios de uso de los existentes, identificar que actividades que requieren energía eléctrica se dejan de hacer y en que horarios, información que no fue incluida en las encuestas con las que se trabajo.

Desarrollo de un modelo de predicción de demanda validado para la gestión de la demanda. Además se plantearon un modelo de predicción que consideran mediciones de los registradores que no fue validad hasta disponer de mediciones. Uno de ellos considera la medición en línea de registradores de demanda como otra entrada de la red neuronal, y incorporando transformadas wavelets en las entradas.

ANEXO I

Predicción de la demanda eléctrica en el tiempo.

Dado que este trabajo de tesis va enfocado a la predicción de demanda a corto plazo en micro-redes, con respecto a esta aplicación específica, y sabiendo de antemano que la demanda en micro-redes tiene diferencias con los sistemas tradicionales, en este anexo se presentan una recolección de los trabajos referentes a este tema, estos estudios aparecen a partir del 2010.

En la tabla 1 se resume los trabajos realizados, las técnicas usadas, tipos de micro-redes, y sus errores.

Año	Técnica	Errores	Capacidad de la micro-red	Autor
jul-10	Red neuronal RBF	3.83%	No tan estocásticas (0-300 y 700 kW)	F. Yuan, M. Leung y L. Zhou
dic-10	Modelo híbrido que combina dos niveles un superior con nueva técnica de búsqueda estocástica optimización conevolución diferencial mejorada EDE (EnhancedDifferentialEvolution) para el ajuste de parámetros del modelo híbrido de predicción en la parte inferior basado en redes neuronales y algoritmos evolutivos para su entrenamiento	2.40%	Micro-red campus universitario de la universidad Calgary-Canadá demanda alrededor de 16MW	N. Amjady, F. Keynia y H. Zaraipour
jun-11	Utiliza redes neuronales con entrenamiento BP con aprendizaje de reglas. La convergencia en entrenamiento usa análisis de la función discreta de Lyapunov	4%	Demanda min 1500 kW, demanda máxima 5000kW promedio 3200kW no tan variable	R. Wai, Y. Chen y Y. Chang
jul-11	Utiliza redes neuronales con una etapa previa de clasificación o multipler classifier systems (MCSs) tiene 4 clases ,una de datos pasados de horas, días, semana y mes del instante a predecir entrenan 4 redes y después se funcionan los pesos .	15.66%	Micro-red en Hong Kong, datosreales señales estocásticas mínima de 4kW, Max 18 kW, media 13kW	P.Can, W. Chen, W. NG y D. Yeung

Dado la presencia que e tema de predicción de la demanda eléctrica a corto plazo es un tema ya estudiado en sistemas tradicionales, en la siguiente tabla se muestra las técnicas usadas en el transcurso del tiempo a partir del 2000.

Año	Técnica	Autor
2012	Modelos aditivos semi-paramétrico	S. Fan, R. Hyndman
2012	Descomposición singular de valores (SVD) basado en suavización exponencial evalúa	J. Taylor
	5 técnicas con ponderación exponencial	
2011	Decisión de lógica difusa	M. Rejc, M. Pantos
2011	Dos Modelos Híbridos	M. Hanmandlu, B. Kumar
	Redes neuronales difusa FNN emplea la integral de Choquet como salida de (FNNCI)	
	Redes neuronales difusa FNN con wavelet a la entrada (WFNN)	
2011	Modelo Híbrido	J. Catalao, H. Pousinho, V. Mendes
	Redes ANFIS con wavelet y PSO	
2011	Modelo Híbrido	H. Kebrriaci, B. Araabi, A. Rhimi
	Usa red neurona con base radial RBF(Radial Base Function) el entrenamiento usa	
	algoritmos genéticos incluyen una función a minimizar una penalización monetaria en lugar de error tradicional	
	más un módulo difuso de Mandami	
2011	Ensamble de redes neuronales	M. Felice, X. Yao
	Usa (RNCL) o aprendizaje de correlación negativa	
2011	Usan redes neuronales, incluyen variables como HI (Heat Index), equivalente a la temperatura percibida por el hombre,	W. Chen, Y. Ping, Z. Wei, W. Jen Lee
	proponen un modelos multi-regiones según el clima	
2011	Realiza predicción de demanda multi-nodal	K. Nose-Folho, A. Diva, C. Minussi
	Primero hace predicciones locales y luego global, para la predicción usan GRNN	
	General regresión neural network que está	
	entrenado en una sola presentación de los patrones de entrenamiento y es capaz de proporcionar resultados rápidos y precisos	
	estima una variable dependiente de una independiente, de estructura no recurrente	
2010	Modelo híbrido	V. Hinojoza y A. Hoese
	Usa razonamiento difuso inductivo (FIR) con algoritmos evolutivos (SAR)	
	simulated rebounding algoritihm para la optimización	
2010	Modelo Híbrido	A. Shekhar, D. Singh, S. Kumar
	Red neuronal con función radial más wavelet a la entrada	

2010	Modelo Híbrido	P. Luh, Y. Chen, C. Guan, Y. Zhao
	Usa red neuronal con wavelet divide la predicción alta y baja	
2010	Estudios del impacto precio de la energía en el mercado para la predicción	H. Zareipour, C. Cañizares y K. Bhattacharya
2010	Estudio sobre la influencia de predicción de variables climáticas en modelos de predicción	D. Fay, J. Ringwood
	Usan modelos lineales y difusos	
2010	Presentan una nueva propuesta de estimación de demanda eléctrica, denominada regresión de vector soporte ponderado localmente	Elattar, J. Goulermas and Q. Wu
	LWSVR (Locally Weighted Support Vector Regression), que combina regresión de vector soporte o máquina de vector soporte	
	con regresión, SVR (Support Vector Regression) y regresión ponderado local LWR (Locally Weighted Regression	
2010	Predicen usando SOM para agrupar días similares de datos de 2 años.	S. Valero, J. Aparicio, C. Senabre
2009	Se basa en el uso de SVR Support Vector Regression	Hinojosa and A. Hoese
2007	Modelo mixto	K. Methaprayoon, W. Lee, S. Rasmiddatta, J. Liao and R. Ross
	El primer bloque en la parte inferior, es donde se realiza propiamente la predicción utilizando redes neuronas	
	a este modelo lo llaman (ANNSTLF Artificial Neural Network Short Term Load Forecasting), utiliza como entradas los datos correctamente	
	validados de las estimaciones de la temperatura, en tiempo real, además de la demanda y temperaturas medidas y proporcionadas por el sistema d	
	e adquisición de datos y en función de estas se obtiene la predicción de la demanda a corto plazo.	
2008	Usan técnicas de suavización y modelos de auto-regresión que consideran como entradas únicamente regresiones de la demanda	Mishra and S. Kumarpatra
2008	Utilizan redes neuronales RBF y ANFIS para la predicción de carga a corto plazo con enfoque en el precio de la energía en tiempo real.	Z. Yun, Z. Quan, S. Caixin, L. Shaolan, L. Yuming, and S. Yang
2007	Usan un modelo ARMA de doble estacionalidad, usando la metodología Box-Jenkins para identificar el modelo más adecuado,	Una de los modelos desarrollados por Taylor [61],
	en función de datos de 20 semanas, para cada una de las series de carga.	
2006	Este modelo predice tanto la demanda como el error de predicción, para las 24 horas, el método de predicción se basa en espacio de estados con filtro Kalman, en conjunto con una base de reglas difusas.	H. Hamadi and S. Soliman
2005	Utilizan modelos de regresión para predicción de la demanda eléctrica, como parte de una estrategia de control de demanda en base a generación	J. Cerda, R. Palma
	distribuida. El modelo propuesto combina dos modelos	

	basados en regresión, Modelo A (para predecir periodos de consumo alto)	
	y modelo B (para predecir periodos de consumo bajo) 6 2	
2005	Usa tres modelos ARX, combinados con una etapa de selección en función a una base de conocimiento,	H. Chen, Y. Du y J. Jiang
	aplicada específicamente a la estación climática de invierno en Texas.	

ANEXO II

Encuestas Aplicadas a Huatacondo

Introducción

En este anexo se describen las encuestas realizadas a la comunidad de Huatacondo y también las encuestas sugeridas, para el desarrollo de este trabajo de tesis.

Encuestas aplicadas y sugeridas

La adquisición de las entradas comprende dos etapas una que es la obtención de información general de la comunidad, para lo cual se utilizó como estrategia información secundaria y visita de terreno, la encuesta propuesta se muestra en la Tabla 41.

Mientras que para la información individual se adjunta la encuesta realizada en la Tabla 42, y en la Tabla 43, Tabla 44 se muestra la encuesta sugerida.

Tabla 41 Encuesta sugerida para obtener información general

Aspecto	Resultado	Horario de funcionamiento		Observación
		Desde	Hasta	
Número de habitantes	72			
Número de casas	31	0:00	0:00	
Número de luminarias del alumbrado público	38	17:00	6:00	P= 200W
Número de micro-empresas	0			
Número de tiendas barriales	1	7:00	20:00	
Número de restaurantes	0			
Número de hoteles u hostales	0			
Número de dispensarios médicos	1			
Área común uno (Camping)	1			Camping
Área común dos (Iglesia)	1			Iglesia
Área común tres (Recreación)	1			Cancha de futbol
Área común cuatro	0			
Número de centros educativos	1	8:00	14:00	
Estaciones climáticas verano	0*			No tan marcada
Estacion climáticas otoño	1*			
Estacion climática invierno	0*			
Estacion climáticas primavera	1*			No tan marcada
Fenómeno natural uno	1*			Invierno boliviano
Fenómeno natural dos	0*			
Fenómeno natural tres	0*			
Actividad económica de la comunidad	Ninguna			
Festividad uno	Carnaval	2		
Festividad dos	Semana Santa	4		
Festividad tres	Cruces	5		
Festividad cuatro	Tirana	16-jul	17-jul	
Festividad cinco	Asunción de la virgen	14-ago	15-ago	
Festividad seis	fiestas patrias	18-sep	20-sep	
Festividad siete	Navidad y año nuevo	24-dic	01-ene	
Festividad ocho				

Tabla 42 Encuesta realizada a la comunidad de Huatacondo

Tópicos de Encuestas Primera Visita a Huatacondo

Antecedentes Personales	
Nombre:	Nelly Gonzalez
Edad:	57.
Nº de Personas	3
Nº de Hijos:	3
Edades:	33 - 32 + 30

1. Dimensión Social

1.1 Relaciones con los vecinos

Descripción: Averiguar cuál es la relación con sus vecinos. Si hay cooperación. Por ejemplo si un vecino viaja, lleva a otros para que no tengan que esperar el bus. Identificar al personaje más conocido en Huatacondo, quien tiene más información, etc.

Bien porque son pocos.
 Algunos vecinos se apoyan. Es un tema de confianza.
 Señora ROSA.
 Hay un furgón del pueblo se viaja 2 veces a la semana en Jauque
 (Sergio Hidalgo)
 Martes - Viernes => Baja en la mañana y en la noche.
 No hay delincuencia. Entre los que hay más confianza

1.2 Migración

Descripción: Averiguar si tienen hijos que se han ido de Huatacondo. En que fechas vienen. Cuanto tiempo se quedan. Averiguar donde se queda la gente cuando viene, ya sean, turistas, familiares, etc.

Hija se caso y hace 12 años que no vive. Se fue porque se caso.
 En el suaves se van por trabajo y para estudiar.
 Por lo general no vuelven. Hay muchas familias que se han ido
 Vacaciones viene su hija - Fiesta de la Ascension (15 Agosto).
 Llena de familiares => la mayoría tiene casas.
 Hoy por los fines de semana. Vienen un rato, no se quedan días de un día.
 Una señora (Yolanda) asienta piezas y tiene teléfono
 1 semana - 3 días (vienen).
 Le hay profesión. Llegan hasta a 4º medio. Hijo manesá camiones para
 empresa

1.3 Inmigración

Descripción: Averiguar si conocen a alguien que sea de otra parte y se haya venido a vivir (como la profesora). Cada cuanto tiempo se va a vivir a Huatacondo.

No hay gente que se viene.

1.4 Salud y Educación

Descripción: Averiguar el nivel de educación de ellos y sus hijos. Si hay una ronda de doctores que los vaya a visitar cada cierto tiempo. Averiguar si tienen potencial para colaborar con la limpieza y mantenimiento de equipos. Averiguar como lo hacen cuando se enferman. Si hay algún curandero.

Ronda medica 1 vez al mes. (1 medico a veces matrona y dentista) 1 dia.
 Hace tiempo habia una persona permanente. (5 años)
 Si alguien se enferma grave se llama a la ambulancia o viajan a la ciudad
 Toman mote, Ajio, Paico. (cosas que hacen en las chacras). Oregano.
 Avisan por telefono cuando viene y enfermera avisa.
 Atienden en la posta.

1.6. Organizaciones Sociales

Descripción: Averiguar la relación que tienen ellos con las organizaciones sociales. Si logran cosas mediante estas organizaciones sociales. Averiguar el actor clave perteneciente a cada una de estas organizaciones y si ellos participan activamente de estas.

Junta de vecinos - Centro de madres - Centro Aymara.

- No participa en ninguna. El marido e hijo si participan.
- ~~El~~ No tiene necesidad de Avidia.
- Solo los que participan les ayudan. Los inscrites. El resto no se considera.

1.7. Vivienda
Descripción: Averiguar si la vivienda es propia, heredada, arrendada o prestada. Averiguar si tienen terrenos en Huatacondo, aparte de la casa.
Vivienda Propia a nombre del marido. Chacras arrendadas, Pocuto. Seguro le dejó al marido uno chiquitito. En los ranchos tienen un poco. Ellos arrendaban . Riegan y mantienen. Chacras no dan, hay poca tierra.

1.8. Fiestas
Descripción: Averiguar: cómo se organizan para la o las fiestas, si venden alimentos, artesanía, etc.
6 días. Parte el 14 y termina como 19 aprox. Son 6 días. Dejada de la Se quedan en sus casas que tienen ACP. los que no tienen casa se quedan en el camping. No tienen grandes problemas durante la fiesta. Vende comida, pan, bebida, licor. tiene que pagar permiso en la municipalidad. 5 personas venden. (Artesanía no). Juntas de vecinos y amigos organizan. Hay muchas cosas que hacer porque se celebran los santos. Año atrás se organizan por ver que se hace. Fiesta de las cruces (cruz de mayo) 2 Mayo vienen los mismos pero menos. solo el mes de mayo (es como el mes de mayo).
2. Dimensión Ambiental

2.1 Flora
Descripción: Averiguar si tienen algún tipo de planta, hierba o hoja de algún árbol que ocupen, saber donde esta para no intervenir en esa zona.
Las que dan fruto. en las chacras.

2.2 Fauna

Descripción: Averiguar si cazan algún tipo de animal, o si tienen alguna adoración a animales, para investigarlo más y no intervenir su hábitat.

No hay adoración, ni caza.

Hay conejo y gallina, cerdo, cabra, chanchó. Están en el corral, esta cerca de la chacra.

No ve aves.

2.3 Agua

Descripción: Averiguar sobre el uso del agua, de donde viene, si tienen pozos, parámetros físicos del agua (color, olor, sabor). Saber si alguien se ha enfermado por el agua.

Consumo y Riego

Agua nunca ha sido buena (salubre).

No hay pozos

Solo por vertiente.

Hay un pozo comunitario y de la plaza hay otro pozo pero como de almacenamiento

2.4 Riesgos Naturales

Descripción: Averiguar sobre hundimientos, remoción en masa, que pasa con el aluvión.

lluvias empieza Enero y termina en marzo.

Se abastecen arroz. se preparan por siccado.

Si se enferma alguien hay de traslado al peso. Piden helicoptero 1 vez y luego.

No hundimiento No remoción en masa (solo terremotos).

Hay barro palud en la mañana. desde arriba y en la tarde desde abajo.

3.3 Apoyo Externo
Descripción: Averiguar si recibe apoyo externo, ya sean, pensión, indemnización, bonos, seguros de vida, etc.
Ns.

3.4 Ingresos y Distribución
Descripción: Averiguar más o menos con cuanto viven y el grado de concentración económica. Quien tiene más dinero en Huatacondo.
<p>a) menos de 100.000 Relativo, depende del periodo.</p> <p>b) entre 100.000 y 200.000</p> <p>c) entre 200.000 y 300.000</p> <p>d) entre 300.000 y 400.000</p> <p>e) más de 400.000</p>

4. Dimensión Institucional

4.1 Municipalidad
Descripción: Averiguar la relación que tiene con la municipalidad. Si ellos proponen algo para mejorar Huatacondo, los apoyan. Como es la relación con el Alcalde.
<p>Bien. Hay apoyo por parte de la municipalidad Trabajo para el marido y permisos para fiestas. Alcalde Relat es regular. No hay inversión.</p>

4.2 Relación con las Minas
Descripción: Averiguar sobre la relación que se tiene con ambas minas. Además pedir que mencionen los beneficios que les han dado, en caso de que existan.
Buena relación Escuela - Iglesia. No apoyo económico. No una cosa.

5. Conductas del Consumo Eléctrico

5.1 Calidad del Suministro
Descripción: Averiguar si se encuentran satisfechos con el sistema eléctrico actual. Si tienen cortes de luz (cuantas veces, y cuanto dura el corte), baja la intensidad de la luz, parpadeo.
<p>Servicio eléctrico.</p> <p>1. ¿Quién mantiene el sistema eléctrico?</p> <p>a. junta de vecinos b. minera (cuál de las dos) c. municipalidad d. alguien específico e. otro f. no sé</p> <p>Jorge Hidalgo encargado de MANTENER el sistema eléctrico. "corte le luz"</p> <p>2. Está conforme con el servicio eléctrico actualmente disponible? (escala 1 a 7 donde 1 es totalmente disconforme y 7 es totalmente satisfecho)6..... ✓ 4 veces de luz. \$2.000 mensual</p> <p>3. En caso de falla del sistema eléctrico ¿A quién recurre?</p> <p><input checked="" type="checkbox"/> a. Persona específica (cuál es su rol.. el eléctrico del pueblo, persona a cargo, alguien con mucha iniciativa propia, etc). Jorge Hidalgo</p> <p>b. Junta de vecinos c. Responsable de la minera d. Alguien de la municipalidad. e. Otro... f. No falla nunca g. Espero a que se arregle solo.</p>

5.2 Usos de la Electricidad

Descripción: Averiguar cuáles son los usos que se le da a la electricidad.

Uso de energía en Actividades Diarias

LAVADORA Hervidor Jugera
 Refri Plancha Blandora (Aveas).
 TV Microondas (con horno) Radio

- Hacer una lista de los artefactos eléctricos que poseen: luz (de qué tipo), microondas, plancha, lavadora, secadora, hervidor, televisor, radio, computador, cargador de celular, refrigerador, etc.
- Completar la tabla de acuerdo al horario en que usan cada uno de los artefactos

2.1 Cuando hay electricidad disponible.

Hora	Artefacto 1	Artefacto 2	Artefacto 3	Artefacto 4	Artefacto 5
14:00 – 14:30			LAVADORA	TV	
14:30 - 15:00					
15:00 – 15:30					
15:30 – 16:00					
16:00 – 16:30					
16:30 – 17:00					
17:00 – 17:30					
17:30 – 18:00					
18:00 – 18:30					
18:30 – 19:00					
19:00 – 19:30					
19:30 – 20:00	Hervidor	Plancha			
20:00 – 20:30					
20:30 – 21:00					
21:00 – 21:30					
21:30 – 22:00					
22:30 – 23:00					
23:30 – 24:00				TV	

1 vez semana 1 vez semana

2.2 Durante periodos sin electricidad Como satisfacen las siguientes necesidades y en que horarios lo hacen. (Van a cargo)

	Fuente	Horario en que se usa.
Iluminación (velas, lámpara a gas, linterna, etc.)	VELAS	Desp. 12.
Calefacción (estufa – tipo –)	—	—
Cocina (leña, carbón, gas)	GAS	3 Comidas.
Agua caliente	Hervidor	
Refrigeración de alimentos.	Refrigerador.	
Comunicación		

(Alternativa B a esta pregunta) Utiliza algún combustible?Cuál? Para qué?

Combustible	Usa (si/no)	Para qué
Leña		
Carbón		
parafina		
Gas licuado		
otro		

-Pregunta de Prueba (analizar la factibilidad de preguntar esto en las primeras familias, si el resultado es positivo, seguir haciendo la pregunta).

Relevancia de artefactos eléctricos.

En tarjetas poner distintos artefactos eléctricos y pedir que los ordenen de mayor a menor en orden de relevancia (poner los 5 primeros no más). Escribir los resultados en la siguiente tabla, y asociar a cierta función (trabajo, entretención, hogar, etc.) y una dimensión (personal, familiar, comunitario). (Puede ser más de una función o dimensión)

Ranking	Artefacto	función	dimensión
1			
2			
3			
4			
5			

5.3 Control de Demanda

Descripción: Averiguar si están dispuestos a participar en el sistema de control de demanda, es decir, saber si están dispuestos a cambiar sus hábitos de consumo y realizar las actividades que requieren electricidad en otros horarios.

Explicarles el sistema de control de demanda y averiguar cuál es el aspecto más importante para ellos (económico, ecológico, mejor calidad en el abastecimiento).

Sí, estaría dispuesto.

2.5 Zonas de Esparcimiento
Descripción: Averiguar si ocupan alguna zona para esparcimiento. (Canchas de futbol, tenis, camping, baño, etc). Saber cuánto lo ocupan. Qué cosas hacen para entretenerse.
<p>En las charcas - fechas Relojas . No hace Recreaciones sociales .</p>

3. Dimensión Económica

3.1 Trabajo
Descripción: Averiguar en qué trabaja. Esta pregunta también es para saber si puede colaborar con el proyecto. Averiguar cuál es la actividad económica predominante. (Agricultura de subsistencia, ganado, servicios, viven de las fiestas, etc.)
<p>No trabaja . Solo en la casa y charca . Venden algunas cosas . Trabaja a veces en la municipalidad . (3 meses - 6 meses) . Arreglar cosas , Plaza, piscinas , etc . No hay conocimiento en construcción .</p>

3.2 Calidad del Empleo
Descripción: Averiguar, si es que trabaja, como es la calidad del empleo, cuantas horas tiene de colación, tiene algún tipo de seguro, cuantas horas trabaja y cuantas veces a la semana.
<p>No horario de colación . Buen trato . Son conocidos . Lunes - a Viernes . les dan permiso . No tienen seguro contra accidente . No muy Beneficios</p>

Tabla 43 Aspectos sugeridos en la encuesta individual, para definir el perfil de demanda en comunidades.

Encuestado	Juan Hidalgo
número_de_miembros	1
edad_miembro_1	88
edad_miembro_2	0
edad_miembro_3	0
edad_miembro_4	0
edad_miembro_5	0
edad_miembro_6	0
actividad_miembro_1	1
actividad_miembro_2	0
actividad_miembro_3	0
actividad_miembro_4	0
actividad_miembro_5	0
actividad_miembro_6	0
ingreso_economico_promedio	100000

Tabla 44 Aspectos sugeridos en la encuesta individual, para definir el perfil de demanda en comunidades.

Equipos eléctricos	Número de equipos actual	Número de equipos futuros
bombillas	4	
tv	1	
decodificador	1	
lavadora	1	
refri	1	
hervidor	0	
plancha	0	
radio	1	
horno eléctrico	0	
maquina de cocer	0	
soldadora	0	
computador	0	
equipo_ música	0	
lámpara	1	
tubo_ fluorescente	0	
foco_ Incandesente	0	
DVD	1	
ventilador	0	
estufa	0	
juguera	0	
congeladora	0	
batidora	0	
microondas	0	
aspiradora	0	
secador de cabello	0	
alisador de cabello	0	
ducha eléctrica	0	
bomba	0	
secadora_ropa	0	
licuadora	0	
notboock	0	

La tabla siguiente muestra la encuesta de horarios de uso de los equipos eléctricos.

ANEXO III

Self-Organizing Maps (SOM)

Introducción

En este anexo se presenta el modelo de red neuronal propuesta por T. Kohonen denominado: Self-Organizing Maps (SOM). Los mapas auto-organizados o SOM (Self-Organizing Maps), también llamados redes de Kohonen son un tipo de red neuronal no supervisada, competitiva, distribuida de forma regular en una rejilla de normalmente, dos dimensiones.

Su finalidad es descubrir la estructura subyacente de los datos introducidos en ella. A lo largo del entrenamiento de la red, los vectores de datos son introducidos en cada neurona y se comparan con el vector de peso característico de cada neurona.

Este algoritmo se ubica dentro del contexto de los algoritmos de entrenamiento para redes neuronales de aprendizaje no supervisado, lo cual implica que ninguna intervención humana es necesaria durante el proceso de entrenamiento; por lo tanto la visualización del conjunto de datos es generada de forma automática.

La principal razón de la popularidad del SOM es su capacidad de presentar de manera automática un mapa en el cual se puede observar una descripción intuitiva de la similitud entre los datos; el despliegue bidimensional tiene la propiedad de presentar la información contenida en los datos de manera ordenada y resaltando las relaciones mencionadas.

La neurona que presenta menor diferencia entre su vector de peso y el vector de datos es la neurona ganadora (o BMU) y ella, y sus vecinas verán modificados sus vectores de pesos.

Este tipo de mapas permiten reducir la dimensionalidad de los vectores de entrada para representarlos mediante una matriz de distancias unificada (U-matriz) generalmente consistente en una matriz 2D, apta para la visualización como una imagen plana.

Redes Neuronales y Auto-organización

En el caso de las redes neuronales artificiales de entrenamiento competitivo, la ausencia de información previa hace necesario contar con algún mecanismo auto-organizante. El mecanismo auto-organizante en estas redes consiste en que la neurona ganadora tiene el potencial de modificar el vector de referencia de las unidades vecinas, la magnitud de la modificación está en función de la distancia física entre la neurona ganadora y cada una de las neuronas vecinas. A partir de esta interacción (ganadora-vecinas) es posible que las neuronas cercanas a la unidad ganadora también aprendan del dato de entrada y modifiquen su vector de referencia con la finalidad de adecuarse al tipo específico de dato. De manera que si una neurona representa a un conjunto de datos sus vecinas representarán datos similares; por lo tanto, las relaciones de similitud son representadas por medio de la cercanía entre las neuronas. El mecanismo auto-organizante que se propone en el SOM consiste de una red neuronal que usa su capacidad de aprendizaje adaptable para representarla estructura geométrica (orden topológico) subyacente en el conjunto de datos de

entrenamiento, la representación es posible gracias a la auto-organización topográfica de las neuronas de acuerdo a las relaciones de similitud entre los datos representadas por la cercanía entre las neuronas y los vectores de referencia correspondientes.

En este sentido, SOM constituye un mecanismo que brinda la posibilidad de producir automáticamente una representación del conjunto de datos en una estructura bidimensional. De manera que en dicha representación se haga evidente la emergencia de propiedades que ayuden a entender el orden geométrico subyacente en el conjunto de datos.


Estructura SOM

- Matriz de neuronas: Las neuronas se distribuyen de forma regular en una rejilla de dos dimensiones, que pueden ser rectangulares o hexagonales, en las que cada neurona puede tener cuatro o seis vecinos respectivamente.

- Espacio de entrada: Los datos de entrada corresponden a un vector de N componentes por cada atributo que queramos comprar, siendo esta dimensión la misma del vector de pesos sinápticos asociado a cada una de las neuronas de la rejilla.

- Espacio de salida: Corresponde con la posición (2D) en el mapa de cada neurona.

- Relación entre neuronas: Entre todas las neuronas hay una relación de vecindad que es la clave para conformar el mapa durante la etapa de entrenamiento. Esta relación viene dada por una función.



Aprendizaje no Supervisado y Entrenamiento Competitivo

Una problemática frecuente en el análisis de datos es que se cuenta con grandes cantidades de datos multidimensionales y por otro lado no se cuenta con información acerca de las relaciones y las estructuras subyacentes del conjunto de los datos; mucho menos se cuenta con una función de distribución o modelo matemático que describa estas estructuras; lo único con lo que se cuenta es con un gran volumen de datos multidimensionales y con una forma de medir la similitud entre ellos.

Dado el gran volumen de datos y su alta dimensionalidad, resulta poco factible la aplicación de técnicas clásicas para la exploración de datos: como son el análisis por componentes principales o los métodos de clustering.

Estas redes neuronales son capaces de encontrar y descubrir, de manera automática, patrones de similitud dentro del conjunto de datos de entrenamiento, y agrupar a los elementos de este conjunto en clusters, de manera que datos similares se agrupen dentro del mismo cluster. Estos descubrimientos pueden realizarse

sin ningún tipo de retroalimentación con el medio externo y sin la utilización de información a priori.

La manifestación más clara del sentido fisiológico en el aprendizaje no supervisado de las redes neuronales artificiales es que “el aprendizaje puede suceder únicamente cuando hay redundancia en la presentación de los datos”. En la práctica esta redundancia se obtiene mediante la utilización iterada de un mismo conjunto de datos, a lo largo de todo el proceso de entrenamiento. En resumen, una red neuronal no supervisada evoluciona durante su entrenamiento, de tal manera que cada unidad de salida será sensible a reconocer y organizar porciones específicas en el espacio de entrada.

Dentro del aprendizaje no supervisado existen dos filosofías principales: el aprendizaje Hebbiano y el entrenamiento competitivo. Las redes neuronales correspondientes al primer caso están orientadas a medir la similitud o a proyectar al conjunto "input" en sus componentes principales, mientras que en el aprendizaje competitivo cada neurona de la red es entrenada para identificar y representar porciones específicas del espacio de entrada.

En las redes neuronales artificiales de aprendizaje competitivo las células reciben de manera idéntica la información de entrada sobre la cual compiten (ver Fig 1). Esta competencia consiste en determinar cual de las neuronas es la que mejor representa a un estímulo de entrada dado. Como resultado de esta competencia solo una neurona es activada en cada momento.




Fig 1 La neurona ganadora de un dato en X es M_c y la neurona M_i es una de las unidades vecinas.

De esta manera, el proceso de entrenamiento competitivo de una red neuronal, determina un sistema dinámico discreto, en el cual cada iteración consiste en la determinación de la neurona ganadora para cada elemento del conjunto de datos.

Una forma de lograr la estabilidad es forzando a un parámetro denominado factor de aprendizaje decrecer y eventualmente converger a cero. De esta manera la red dejará de aprender y por lo tanto se mantendrá estable. Sin embargo, este congelamiento artificial del aprendizaje ocasiona que se pierda la plasticidad de la red, es decir la habilidad de adaptarse a nuevos datos. El dilema entre forzar la estabilidad y mantener la plasticidad durante el proceso de entrenamiento en una red neuronal es conocido como: "dilema de estabilidad plasticidad" de Groosberg.

Una de las ventajas más significativas en las aplicaciones es que generalmente los modelos de redes neuronales basados en aprendizaje competitivo tienen arquitecturas muy simples y cuentan con algoritmos de entrenamiento más rápidos que otras redes neuronales como los perceptrones multi-capas. La más famosa de las redes neuronales no supervisadas competitivas es la propuesta por Kohonen (SOM). El resultado del aprendizaje competitivo en el caso del SOM es una partición del conjunto de datos de entrada inducida por la distribución de los datos en las neuronas. Ésta partición se realiza de manera que datos similares son agrupados por la red y representados por una sola neurona. Dicha neurona es la unidad ganadora para cada uno de los datos asociados durante la última iteración en el proceso de entrenamiento.

Por lo tanto, la agrupación de los datos es realizada de manera automática, basándose en la similitud entre los datos y en la distribución de las respectivas neuronas ganadoras localizadas a lo largo y ancho de una retícula bidimensional.

Entrenamiento SOM

El modelo de red neuronal del SOM pertenece al tipo de redes neuronales de aprendizaje no supervisado lo cual significa que ninguna intervención humana es necesaria durante el proceso de entrenamiento y que muy poco es necesario saber acerca de las características del conjunto de datos de entrada. El entrenamiento lleva a cabo mediante un proceso de aprendizaje competitivo en el cual las neuronas se vuelven gradualmente sensibles a diferentes categorías de los datos de entrada.

En cada momento t del proceso de entrenamiento, un vector de entrada $x(t) \in \mathbb{R}^n$ es conectado a todas las neuronas en paralelo vía los vectores de referencia de cada neurona. Las neuronas compiten para ver cual de ellas es capaz de representar de mejor manera al dato de entrada $x(t)$.

Dado cualquier $x \in X$ la competencia consiste en encontrar la neurona tal que su vector de referencia w_c cumpla con:

$$\|x - w_c\| = \min_{i=1}^N \{\|x - w_i\|\} \quad (1)$$

a la neurona ganadora η_c se le define como el nodo que mejor representa al dato x . Nótese que el subíndice c es función de x ; para cada x existe un $\eta_{c(x)}$. En caso de que este índice no esté bien definido, es decir cuando para un dato x existan dos $\eta_e, \eta_d \in N$ tal que:

$$d(x, \eta_e) = \min \{d(x, \eta_i) | i = 1, \dots, k\} = d(x, \eta_d)$$

la selección de un único $c(x)$ debe hacerse de manera aleatoria. Por simplicidad se adoptará la siguiente notación:

$$x \sim \eta \Leftrightarrow \eta = \eta_{c(x)}$$

Generalmente se utiliza la distancia Euclidiana para determinar el nodo que mejor representa a un dato en (5); sin embargo, se pueden usar otras normas. Para cada tiempo t se realiza la competencia (5) de manera que se puede definir $c = c(t)$ tal que $x(t) \sim \eta_{c(t)}$, aquellas neuronas que se encuentran dentro de una vecindad de $\eta_{c(t)}$ en el arreglo bidimensional (Fig 2) aprenderán de la misma entrada $x(t)$. La vecindad de $\eta_{c(t)}$ sobre la retícula se define a partir del vector de localización $r_{c(t)}$ de la siguiente manera:

$$N_{c(t)} = \{i \in N \mid \|r_{c(t)} - r_i\| \leq \rho(t)\} \quad (6)$$

donde $\rho(t)$ es el radio de la vecindad en el tiempo t . Como se observa en 6, el radio de la vecindad varía en función de t . Para efectos de la convergencia del algoritmo, la variación del radio a través del tiempo debe cumplir las siguientes condiciones (Fig 2):

$$\begin{aligned} \text{Si } t_i \leq t_j &\Rightarrow \rho(t_i) \geq \rho(t_j) \\ \rho(t) &\rightarrow 0 \text{ cuando } t \rightarrow \infty \end{aligned}$$

Debe tenerse cuidado al escoger el tamaño inicial de $\rho(0)$, si desde un comienzo la vecindad es muy pequeña, el mapa no se ordenará globalmente, lo cual implicará que el mapa generado se verá como un mosaico de parcelas entre las cuales el ordenamiento cambia discontinuamente. Para evitar este fenómeno $\rho(0)$ puede comenzar siendo más grande que la mitad del diámetro de la red.

Para iniciar el proceso de aprendizaje se utilizan valores aleatorios para los vectores de referencia $w_i(0)$. En las versiones más simples del SOM los valores sucesivos para los vectores de referencia se determinan recursivamente por el siguiente mapeo de iteraciones:

$$w_i(t+1) = w_i(t) + h_{ci}(t)[x(t) - w_i(t)]$$

La función $h_{ci}(t)$ desempeña un papel fundamental en este proceso. A esta función se le conoce como función vecindad. En la literatura es común encontrar que esta función tenga la forma:

$$h_{ci}(t) = \left(\|r_{c(t)} - r_i\|, t \right) \quad (2)$$

lo cual implica que el valor de la función depende de la distancia entre el neurona η_i y la neurona ganadora $\eta_{c(t)}$ en el tiempo t . El ancho promedio $\rho(t)$ y forma de $h_{ci}(t)$ definen la rigidez del mapa que será asociada a los datos. Independientemente de cual sea la forma explícita de la función 2, debe ser tal que $h_{ci}(t) \rightarrow 0$ mientras $\|r_{c(t)} - r_i\|$ se incrementa. Una de las definiciones más simples que se encuentran de la función vecindades la siguiente:

$$\begin{aligned} h_{ci}(t) &= \alpha(t) \text{ si } i \in N_c(t) \\ h_{ci}(t) &= 0 \text{ si } i \notin N_c(t) \end{aligned} \quad (3)$$

El valor de $\alpha(t)$ se define como factor de aprendizaje el cual cumple con la condición $0 < \alpha(t) < 1$ y usualmente $\alpha(t)$ es una función monótona decreciente. Otra forma común de la función vecindad está dada en términos de la función Gaussiana:

$$h_{ci}(t) = \alpha(t) \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right) \quad (4)$$

donde $\alpha(t)$ es el factor de aprendizaje y el parámetro $\sigma(t)$ corresponde al ancho promedio de $N_c(t)$, en este caso $\rho(t) = \sigma(t)$. Tanto $\alpha(t)$ como $\sigma(t)$ son funciones escalares decrecientes con respecto al tiempo. La definición de estas funciones debe tener como consecuencia del cumplimiento de básicamente dos etapas del proceso durante el proceso de entrenamiento: ordenamiento global y refinamiento.




Fig 2 Variación en el tiempo del radio de la vecindad

Etapas del entrenamiento

Ordenamiento Global: Según lo reportado por T. Kohonen, durante aproximadamente las primeras 1000 competencias se lleva a cabo el ordenamiento de los datos a lo largo y ancho del mapa. Este ordenamiento consiste en establecer los pesos de cada neurona para que estas sean capaces de identificar cierto subconjunto característico dentro del conjunto de datos X y para que las relaciones de cercanía entre las distintas neuronas del mapa reflejen cercanía de los datos correspondientes en el espacio multidimensional del cual provienen. Si los valores iniciales de los pesos han sido seleccionados de manera aleatoria, durante estos primeros 1000 pasos los valores de $\alpha(t)$ deben comenzar siendo razonablemente grandes (cerca de la unidad) e ir descendiendo hasta llegar a valores cercanos a 0,2. En general, la forma de $\alpha(t)$ no es importante, puede ser lineal, exponencial o inversamente proporcional a t . Es importante señalar que la selección óptima de estas funciones y sus parámetros solo pueden ser determinadas

experimentalmente; ya que no existe algún resultado analítico que garantice dicha selección óptima.

Refinamiento :Después de la fase de ordenamiento los valores de $\alpha(t)$ deben ser pequeños y decrecer lineal o exponencialmente durante la fase fina. Dado que el aprendizaje es un proceso estocástico, la precisión final del mapa dependerá del número de pasos en esta etapa final de la convergencia, la cual debe ser razonablemente larga. El número de pasos debe ser del orden de 100000. Por otro lado, cabe señalar que la cardinalidad del conjunto X no es relevante para determinar este número de pasos. Nótese que el algoritmo es computacionalmente ligero y que el conjunto X puede ser reciclado para lograr tantos pasos como sea necesario.

Una vez concluido el proceso de entrenamiento, el SOM define una regresión no-lineal que proyecta un conjunto de datos de dimensión alta en un conjunto de vectores de referencia, por lo que dicho conjunto sirve para obtener una representación del conjunto de datos en una red adaptable ("elástica") de dos dimensiones en la cual se pueden observar las relaciones de similitud y la distribución de los datos. De esta manera es posible construir una representación bidimensional de un conjunto de datos multidimensional. En la Fig 3, se mira la gráfica de los vectores de referencia durante el proceso de entrenamiento de un SOM con retícula rectangular, las adyacencias entre los vectores de referencia se refieren a las adyacencias entre neuronas vecinas en la red. El algoritmo implementado utiliza 4 como función de vecindad. Las distintas figuras corresponden a distintas distribuciones del conjunto de entrenamiento; en todas, la condición inicial de los vectores de referencia es aleatoria

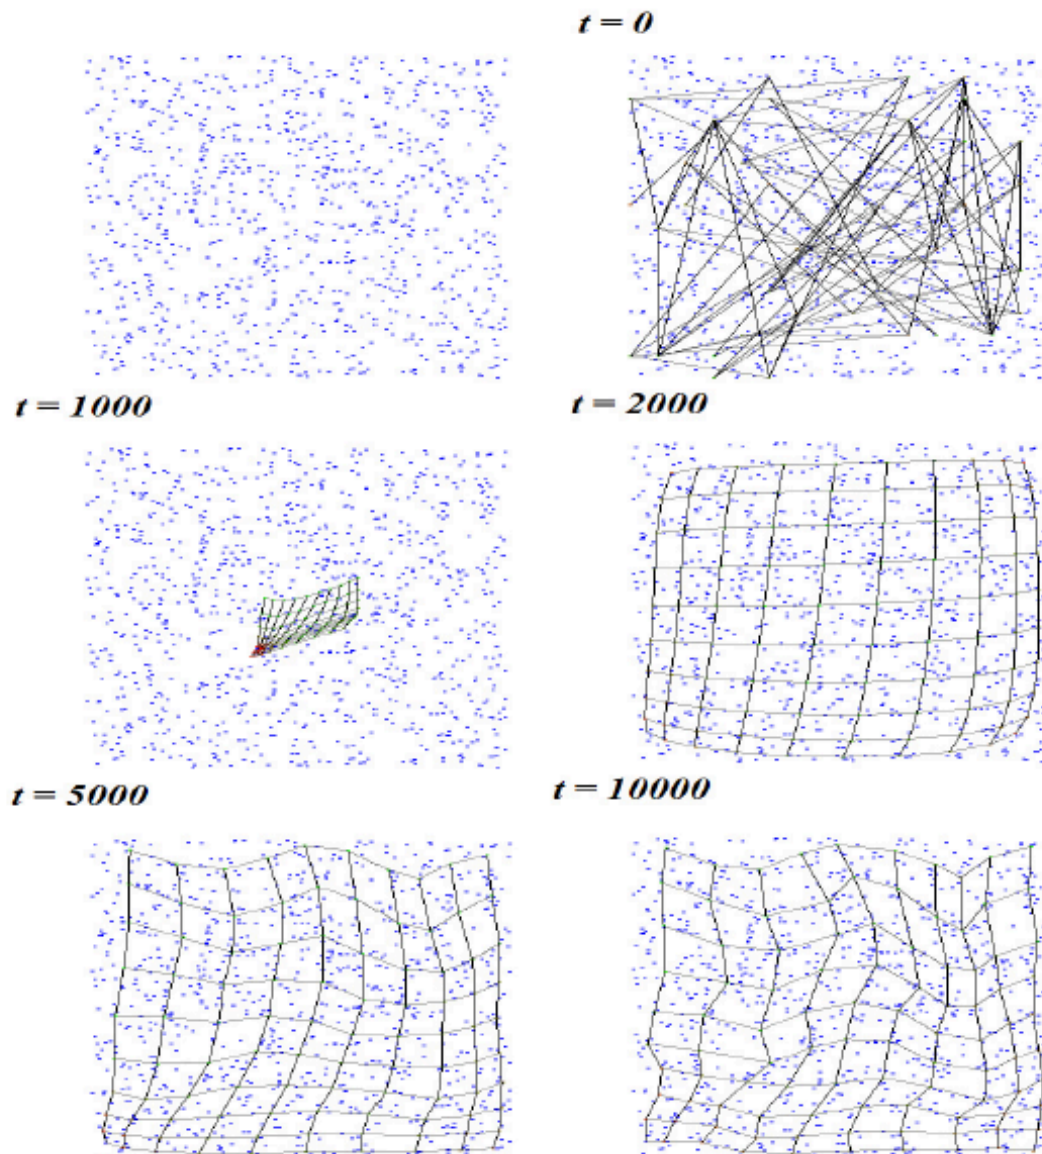


Fig 3 Evolución del entrenamiento de un SOM con 10 X 10 neuronas y un conjunto de 1000 puntos con distribución uniforme de sobre el plano.

Visualización de Información y Mapas del Conocimiento

"Los mapas de conocimiento son representaciones gráficas de las conexiones hechas por el cerebro en el proceso de entendimiento de los hechos". Dichos mapas constituyen un medio visual en el cual ideas complejas puedan ser expuestas de manera rápida y en un orden lógico. La representación proporcionada por los mapas resulta de gran utilidad en el descubrimiento de características presentes en el conjunto de datos, de las que no se tenía conocimiento previo.

En una gran cantidad de aplicaciones los mapas topográficos que se producen a partir del SOM resultan ser poderosas herramientas de análisis; el algoritmo SOM tiene la capacidad de producir medios visuales que representen las relaciones y estructuras de similitud entre los datos. Los mapas generados a partir del SOM resultan ser útiles para el descubrimiento de información previamente desconocida y relevante en la

comprensión del fenómeno correspondiente al conjunto de datos. En este sentido, "el SOM representa una herramienta que puede ser utilizada para la generación automática de mapas del conocimiento".

SOM es muy usado en representación de datos en:

- Reducción de la multi-dimensionalidad: Se puede representar conjuntos de datos de gran número de atributos en mapas 2D.
- Asociación de elementos con atributos similares: Visualmente se puede ver de forma rápida como quedan agrupados elementos que tienen valores próximos entre sí.

Aparte de estas razones a nivel técnico se tiene muchas ventajas como:

- Facilidad de implementación: La implementación de un sistema SOM es relativamente fácil y se adapta perfectamente al modelo de procesado en paralelo por lo que es también muy fácilmente optimizable.
- Abstracción de los datos de entrada: Los SOM son totalmente transparentes a la naturaleza de los datos de entrada, tan solo se limitan a comparar vectores de entrada con los pesos sinápticos de las neuronas de la rejilla. Esto hace que pueda ser usado en gran variedad de problemas sin tener necesidad de cambiar la aplicación base.
- Facilidad de integración con otras técnicas: Esta técnica se puede compaginar con otras técnicas de obtención de conocimiento como pueden ser las redes bayesianas realizando un pre-procesado del conjunto de datos. Recientemente se está produciendo un crecimiento del uso de mapas SOM gracias a su potencia y facilidad de uso para trabajar en campos como la estadística.

Además una vez obtenida el mapa, la representación no tiene porque limitarse a una rejilla rectangular, como se puede apreciar en la Fig 4.

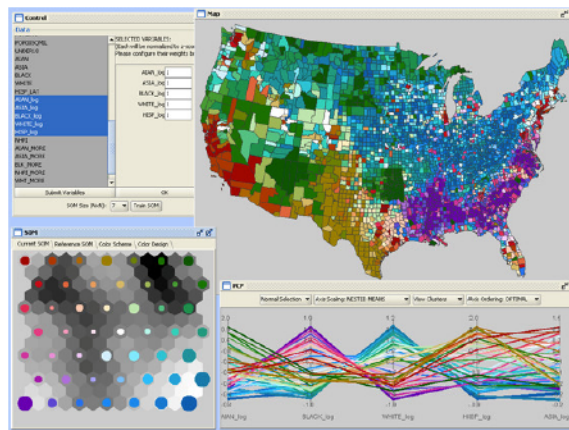


Fig 4 Ejemplo de uso de SOM en aplicaciones estadísticas

Bajo las dos usos de SOM se usa como:

Visualización del ordenamiento del conjunto de datos

El ordenamiento producido por la regresión permite el uso de los mapas como un despliegue de los datos. Cuando los datos son mapeados a aquellas unidades en el mapa que tienen los vectores de referencia más cercanos, las neuronas vecinas serán similares a los datos mapeados dentro de ellas. Este despliegue ordenado de los datos facilitará la comprensión de las estructuras subyacentes en el conjunto de datos.

El mapa puede ser usado como un campo de trabajo ordenado en el cual los datos originales pueden ser dispuestos en su orden natural. Las variables se aplanan localmente en el mapa, lo cual ayuda a penetrar en las distribuciones de los valores del conjunto de datos. Este mapa es mucho más ilustrativo que tablas

de columnas con estadísticas linealmente organizadas. Estas características de los mapas generados por el SOM, permiten que el SOM sea útil para la generación de mapas de conocimiento los cuales son de gran utilidad en el proceso de descubrimiento de conocimiento en bases de datos.

Visualización de clusters

El mapa resultante análisis del conjunto de datos puede ser usado para ilustrarla densidad de las acumulaciones en diferentes regiones en el espacio U en las cuales es posible observar relaciones de similitud. La densidad de los datos del conjunto de entrada X es representada por su acumulación en los vectores de referencia. En las áreas de acumulación los vectores de referencia serán cercanos y el espacio vacío entre ellos se hará cada vez más escaso. Por lo tanto, la estructura de clusters en el conjunto de datos puede vislumbrarse por la disposición de las distancias entre los vectores de referencia de las unidades vecinas. El diagrama de acumulación resultante es muy general en el sentido de que no se necesita asumir nada acerca del tipo clusters. Sin embargo, para lograr definir los clusters es necesaria la aplicación de algún algoritmo de clustering sobre los vectores de referencia.

ANEXO IV

Redes Neuronales Artificiales

Introducción

En este anexo se describe las características principales de las neuronales

Perceptrón Multicapa (MLP)

La Fig5 muestra la estructura básica de un Perceptrón Multicapa (del inglés Multilayer Perceptron o MLP) con una capa de entrada, dos capas ocultas y una de salida. En este tipo de arquitectura neuronal, todas las neuronas de una capa están conectadas a las neuronas de la capa precedente. Todas las señales fluyen en la misma dirección: hacia adelante. La capa de entrada generalmente no está constituida por neuronas (representadas en la figura como pequeños cuadros), ya que no realizan procesamiento alguno, siendo su única función la de alimentar el vector de entrada a la primera capa oculta. La salida de una capa de neuronas queda según la ecuación (1):

$$\bar{a} = f(\bar{w}\bar{p} + \bar{b}) \quad (1)$$

siendo \bar{a} el vector de salidas de la capa, \bar{w} el vector de pesos, \bar{b} el vector de bias, \bar{p} el vector de entradas a la capa y f es la función de transferencia de la neurona.

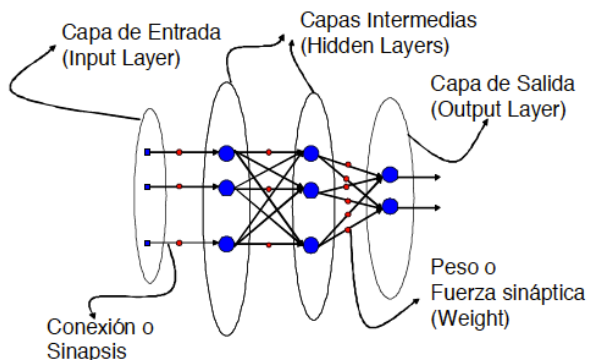


Fig5 Red neuronal alimentada hacia adelante tipo MLP, con dos capas de neuronas ocultas.

Simulación o ejecución de la red neuronal

El comportamiento de las redes neuronales artificiales viene dado por su función de transferencia. Una red de N capas, con unos determinados pesos y bias en las conexiones entre cada una de las capas que conforman la red neuronal, posee un comportamiento definido por la ecuación (2).

$$\bar{a} = f_N(\bar{b}^N + \bar{W}^N [f_{N-1}(\bar{b}^{N-1} + \bar{W}^{N-1} \dots [f_1(\bar{b}^1 + \bar{W}^1 \dots \bar{p}) \dots]]) \quad (2)$$

donde N es el número de capas de la red y \bar{p} es un vector de entrada. Esta función indica que para cada vector de entrada \bar{p} se obtiene un vector de salida \bar{a} , mediante la propagación de señales desde la capa de entrada hacia la capa de salida, como muestra la Fig6. Cada uno de los vectores de entrada se denomina patrón de entrada a la red neuronal. La fase de ejecución de un MLP es una operación computacional muy

rápida consistente en la realización de sumas de productos, que puede realizarse en tiempo real.




Fig6 Dirección del flujo de información durante la ejecución de un MLP.

Entrenamiento de un MLP

El conocimiento de la red neuronal se encuentra en los pesos de las conexiones entre las distintas capas que forman la red neuronal. Durante el proceso de entrenamiento, la red va cambiando los pesos de sus conexiones de forma que la función de transferencia de la red se ajuste al objetivo. El algoritmo más utilizado para realizar este ajuste es el denominado Backpropagation (propagación hacia atrás del error).

Este algoritmo de aprendizaje se basa en propagar el error de salida de cada capa hacia la capa anterior, de forma que se ajusten los pesos de cada capa de manera independiente.

El error en la capa de salida $e_j(k)$ se define como la diferencia entre los objetivos (salidas deseadas) $t_j(k)$ y las salidas reales obtenidas de la red $a_j(k)$ para los diversos patrones de entrada. El error en cada nodo de salida j de la red neuronal viene dado por la ecuación (3):

$$e_j(k) = t_j(k) - a_j(k) \quad (3)$$

donde k indica el número de la iteración.

El objetivo del algoritmo Backpropagation es minimizar la suma de los errores cuadráticos medios de la salida de la red neuronal, dada por la ecuación (4):

$$\varepsilon(k) = \frac{1}{2} \sum_{j=1}^S e_j^2(k) \quad (4)$$

El error medio de todos los patrones de entrada del sumatorio del error cuadrático viene dado por la ecuación (5):

$$\varepsilon = \frac{1}{Q} \sum_{k=1}^Q \varepsilon(k) \quad (5)$$

siendo Q el número de patrones de entrada disponibles. El objetivo del entrenamiento es minimizar este error "a la salida. Para ello se aplica una corrección de los pesos y bias de la red neuronal proporcional al gradiente del error instantáneo, que utilizando la regla de la cadena queda como muestra la ecuación (6):

$$\frac{\partial \varepsilon(k)}{\partial w_{i,j}(k)} = \frac{\partial \varepsilon(k)}{\partial e_j(k)} \frac{\partial e_j(k)}{\partial a_j(k)} \frac{\partial a_j(k)}{\partial v_j(k)} \frac{\partial v_j(k)}{\partial w_{i,j}(k)} \quad (6)$$

donde v_j es el estado interno de la neurona j . Evaluando por partes esta ecuación, obtenemos:

$$\varepsilon(k) = \frac{1}{2} \sum_{j=1}^S e_j^2(k) \Rightarrow \frac{\partial \varepsilon(k)}{\partial e_j(k)} = e_j(k) \quad (7)$$

$$e_j(k) = t_j(k) - a_j(k) \Rightarrow \frac{\partial e_j(k)}{\partial a_j(k)} = -1 \quad (8)$$

Si llamamos ϕ_j a la función de activación de la neurona

$$a_i(k) = \varphi_j(v_j(k)) \Rightarrow \frac{\partial a_j(k)}{\partial v_j(k)} = \varphi'_j(v_j(k)) \quad (9)$$

$$v_j = \sum_{i=0}^P w_{ij}(k) a_i(k) \Rightarrow \frac{\partial v_j(k)}{\partial w_{i,j}(k)} = a_i(k) \quad (10)$$

La variación de los pesos de cada capa viene dado por la ecuación (11):

$$\frac{\partial \varepsilon(k)}{\partial w_{i,j}(k)} = -e_j(k) \cdot \varphi'_j(v_j(k)) \cdot a_i(k) \quad (11)$$

Por tanto, el incremento viene dado por la ecuación (12):

$$\Delta w_{i,j}(k) = -\alpha \frac{\partial \varepsilon(k)}{\partial w_{i,j}(k)} = \alpha e_j(k) \cdot \varphi'_j(v_j(k)) \cdot a_i(k) = \alpha \delta_j(k) \cdot a_i(k) \quad (12)$$

siendo δ_j el gradiente local.

$$\delta_j(k) = e_j(k) \cdot \varphi'_j(v_j(k)) \quad (13)$$

Para calcular el gradiente del error de cada neurona de cada capa necesitamos conocer el estado interno de la neurona, al que se le aplica la derivada de la función de activación, y el error de salida de la neurona. Este error de salida de cada neurona se conoce en las capas de salida. Para conocer el error de salida en las capas ocultas, el error se propaga hacia atrás desde la capa de salida.

Si el nodo j pertenece a la capa de salida, el error en esa capa es conocido, tal y como se mostró en la ecuación (3). Si el nodo j pertenece a una capa oculta n , y el nodo h a la capa $n + 1$ el error en la capa n queda según la ecuación (14):

$$e_j(k) = -\frac{\partial \varepsilon(k)}{\partial a_j(k)} = \sum_{h \in n+1} \frac{\partial \varepsilon(k)}{\partial v_h(k)} \frac{\partial v_h(k)}{\partial a_j(k)} = \sum_{h \in n+1} e_h(k) \varphi'_h(v_h(k)) \quad (14)$$

Para calcular el error por retro-propagación utilizamos el método de dos pasadas.

- 1.- En la pasada hacia delante se simula la red, almacenando el estado interno de las neuronas de cada capa (Fig6).
- 2.- En la pasada hacia atrás, se retro-propaga el error (Fig7).




Fig7 Dirección del flujo de información durante la fase propagación hacia atrás del error.

Se ajustan los pesos y bias de cada capa en función del gradiente local del error:

$$\Delta w_{i,j}(k) = \alpha \delta_j(k) \cdot a_i(k) \quad (15)$$

Este gradiente se calcula de forma recursiva:

$$\delta_j(k) = \varphi'_j(v_j(k)) \cdot e_j(k) = \varphi'_j(v_j(k)) \cdot \sum_h \delta_h(k) w_{hj}(k) \quad (16)$$

Mejoras al algoritmo Backpropagation. Métodos alternativos

Para aumentar la velocidad de convergencia del algoritmo Backpropagation se han propuesto numerosos métodos que hacen más eficiente el proceso de aprendizaje de la red. La primera mejora se consiguió añadiendo a la regla de modificación de los pesos un término denominado momento (momentum). Este término añade un efecto de inercia que permite acelerar la velocidad de convergencia cuando el incremento de los pesos tiene siempre el mismo signo, mientras que su aportación queda anulada si el signo del incremento oscila.

Otras propuestas han consistido en la utilización de funciones de transferencia alternativas a la sigmoide, como por ejemplo la función tangente hiperbólica ($f(x) = \operatorname{atanh}(bx)$).

Otras propuestas han utilizado implícitamente o explícitamente las derivadas segundas.

Así, del denominado algoritmo Quickprop utiliza heurísticas para encontrar información de cómo son las derivadas segundas, pero sin tener que calcularlas.

Finalmente, los métodos de segundo orden se basan en realizar el descenso por el gradiente de pesos utilizando información proporcionada por el ritmo de cambio de la pendiente. Ejemplos de estos métodos son los denominados Gradientes Conjugados, Gradientes Conjugados Escalados y Levenberg-Marquardt.

Backpropagation con ganancia adaptativa

El entrenamiento Backpropagation adaptativo sigue los principios de retro-propagación del error que se han visto anteriormente, pero utiliza una tasa de aprendizaje adaptativa. Una tasa de aprendizaje pequeña hará el entrenamiento más largo y estable, mientras que un valor alto incrementará considerablemente el tiempo de convergencia. Sin embargo, si el valor de la tasa de aprendizaje es muy alta, puede hacer el proceso de entrenamiento inestable. Con el ajuste del paso del entrenamiento Backpropagation adaptativo se consigue, por tanto, un entrenamiento más eficiente, intentando ajustarlo para conseguir la velocidad de entrenamiento máxima posible, asegurando en todo momento que el entrenamiento no llegue a la inestabilidad.

Para ello, se requieren tres parámetros adicionales en el entrenamiento de la red neuronal:

Tasa de incremento. Indica cuánto se debe aumentar el paso si el entrenamiento así lo cree oportuno.

Tasa de decremento. Indica cuánto se debe decrementar el paso si el entrenamiento debe reducir el tamaño del paso porque se ha vuelto inestable.

Tasa de error. Rango donde el error puede aumentar sin que se considere que el sistema puede estar oscilando.

El valor de estos parámetros para realizar un correcto aprendizaje de la red neuronal se deben establecer de forma heurística, mediante el método de prueba y error, la mayoría de las veces basados en la propia experiencia del diseñador de la red neuronal.

En cada iteración del entrenamiento de la red neuronal se evalúa la variación del error cometido respecto a la iteración anterior. En este análisis del error se pueden llegar a tres estados deferentes:

1. Si el error ha disminuido, el entrenamiento de la red es correcto y se puede aumentar la tasa de aprendizaje para acelerar el entrenamiento.
2. Si el error ha aumentado por encima del la tasa de error, la red tiende hacia un estado inestable. No se modifican los pesos y bias en esa iteración y se reduce la tasa de aprendizaje para evitar la inestabilidad.
3. Si el error ha aumentado por debajo de la tasa de error, es posible que la red deba superar un mínimo

local en su función de aprendizaje. Por ello, se modifican los pesos y bias de la red de acuerdo a los valores obtenidos en esa iteración, pero no se altera el valor del paso del entrenamiento.

Con estas modificaciones, a costa de un incremento computacional pequeño, la convergencia del MLP suele ser mucho más rápida que con el método Backpropagation básico y, en la mayoría de los casos, suele evitar muchos mínimos locales.

Redes de funciones base radiales (RBF)

Las redes neuronales de Funciones Base Radiales (del inglés, Radial Basis Function Networks) son del tipo alimentadas hacia delante, con una arquitectura de tres capas, como muestra la Fig8. La capa de entrada se utiliza para presentar a la red los patrones de entrada. La segunda capa o capa oculta está constituida por neuronas no lineales, y la capa de salida por neuronales con funciones de transferencia lineales.




Fig8 Estructura de una red de funciones base radiales.

La capa oculta proporciona un conjunto de funciones que constituyen una base arbitraria para los patrones de entrada (vectores de entrada) cuando éstos son alimentados al espacio de las unidades ocultas. De esta forma, las neuronas ocultas se denominan funciones base radiales (el término inglés correspondiente es radial-basis functions).

Estas funciones de transferencia tienen dos parámetros, centro y ancho. La ecuación (17) muestra una posible elección:

$$f_i(x) = e^{-\frac{\|c_i - x\|^2}{2\sigma_i^2}} \quad (17)$$

donde x representa el vector de entrada, c_i es el centro de la neurona i y σ_i determina el ancho de la neurona i . Los parámetros c_i y σ_i de cada neurona se fijan durante el proceso de entrenamiento, así como los pesos de la capa de salida. El término radial se debe a la simetría radial de estas funciones con respecto al centro c_i . La función de transferencia de una red RBF viene dada por la ecuación (18):

$$y_k(x) = \sum_{i=1}^M w_{k,i} f_i(\|c_i - x\|, \sigma_i) \quad (18)$$

donde y_k es la salida de la k -ésima neurona de salida de la red, $w_{k,i}$ es el peso de la conexión entre la neurona de salida k y la neurona oculta i , M es el número de neuronas ocultas, y f_i viene dada por la ecuación (17).

Entrenamiento de RBF

El primer paso en el entrenamiento de una red RBF (al igual que con otros paradigmas) es encontrar el número de neuronas óptimo para resolver un problema particular. En el caso de las neuronas RBF, cada una de ellas cubre una parte del espacio de entrada, por lo que habrá que elegir un número suficiente que cubra todo el espacio de entrada. Sin embargo, debido a que el número de neuronas necesarias para cubrir este espacio crece exponencialmente con la dimensión de los vectores de entrada generalmente, se hace necesario llegar a un compromiso entre la precisión de la solución y el número de neuronas. Además, como con la red MLP, un excesivo número de neuronas ocultas puede producir una sobre-parametrización de la red, lo que repercutirá negativamente en su capacidad de generalización. En este sentido, las técnicas que se emplean comúnmente para la determinación del número de neuronas ocultas en un MLP pueden también ser aplicadas al caso de las redes RBF. Entre ellas, el método de prueba y error suele emplearse frecuentemente, aunque existen otras técnicas más eficientes como el algoritmo

Auto-Organizado jerárquico. Una vez determinado el número de neuronas base radiales, debemos encontrar los parámetros de la arquitectura. En este sentido, a diferencia del entrenamiento de la red MLP, suele utilizarse un método por etapas, donde en primer lugar se entrenan las neuronas ocultas y, en una segunda etapa, las neuronas de salida. En la primera etapa, el proceso de entrenamiento de la red consiste en encontrar los parámetros c_i y σ_i de forma que minimicen alguna medida de error. Para los parámetros c_i , entre los algoritmos más utilizados podemos destacar los siguientes:

- Selección aleatoria.
- Selección de centros mediante el algoritmo k-medias.

Una vez fijados los parámetros c_i , debemos encontrar los parámetros de escala σ_i , que suele hacerse mediante técnicas heurísticas. Las ecuaciones (18) y (19) muestran dos procedimientos ampliamente utilizados. La primera ecuación calcula de forma aproximada la influencia en el espacio de entrada de cada neurona en relación a las demás. La segunda se basa en el cálculo del promedio de la distancia de diversos patrones representativos al centro c_j .

$$\sigma_i^2 = \frac{1}{N} \sum_{l=1}^N \|c_l - c_j\|^2 \quad (18)$$

$$\sigma_i^2 = \frac{1}{N_j} \sum_{x \in \text{nodos}_j} \|x - c_j\|^2 \quad (19)$$

La última etapa del entrenamiento consiste en el aprendizaje de la capa de salida, esto es, determinar el valor de los pesos w_{ij} . En este caso, una vez fijados los parámetros de las neuronas ocultas c_i y σ_i , los pesos $w_{i,j}$ se calculan aplicando el algoritmo LMS (Least Mean Squares) a la expresión de la salida de la capa de salida según la ecuación (20):

$$z_k = \sum_j w_{k,j} f_r(c_i, \sigma_i) + \theta_k \quad (20)$$

donde f_r representa la salida de una neurona de la capa oculta y θ_k es el bias de la neurona.

Los pesos se obtienen mediante la ecuación (21):

$$w_{k,j}(t+1) = w_{k,j}(t) + \varepsilon(t_k - z_k) f_r(c_i, \sigma_i) \quad (21)$$

donde t_k son los valores objetivos o salidas deseadas. Finalmente, señalar que con respecto al

entrenamiento de una red MLP, el entrenamiento de una red RBF es más eficiente debido a que éste se realiza en dos etapas.

Red recurrente de Elman

La red de Elman forma parte de las denominadas redes parcialmente recurrentes. Tienen la forma general de un MLP, pero se añaden conexiones recurrentes. Está constituida por una capa oculta con función de activación tangente hiperbólica y una capa de salida con función de activación lineal. Las conexiones recurrentes parten de la salida de la capa oculta y se realimentan como entradas a esta misma capa, como muestra la Fig9. Las recurrencias de este modelo neuronal le permite tanto detectar como generar patrones que van cambiando lo largo del tiempo.

Al igual que el MLP, su estructura de dos capas le permite aproximar cualquier función que tenga un número n de discontinuidades con una precisión especificada, con la única condición de que el número de neuronas ocultas sea suficiente. Las realimentaciones aportan a la red, en la iteración t , información sobre el estado de la misma en la iteración $t-1$.

Al igual que el modelo de Jordan, esta red puede ser entrenada con los algoritmos diseñados para el MLP con un mínimo de cambios. A continuación, esbozamos el algoritmo básico de entrenamiento para la red de Elman:

Para cada época:

1. Presentar los patrones a la red, y calcular las salidas.
2. Calcular el error de las salidas, comparándolas con las salidas deseadas.
3. Para cada patrón presentado, calcular el incremento de los pesos y bías utilizando el algoritmo Backpropagation. En esta etapa el gradiente de los pesos y bías de las conexiones recurrentes se ignoran.
4. Actualizar el vector de pesos de cada neurona.

El inconveniente de esta red frente al MLP es que la adaptación de los pesos utiliza una aproximación del gradiente del error. Por esta razón, para que una red de Elman pueda resolver el mismo problema que un MLP, generalmente requerirá de un número mayor de neuronas ocultas ([Demuth and Beale, 2000]). Por otro lado, aporta varias ventajas importantes.

En primer lugar, la realimentación de señales proporciona a la red estados internos y memoria, haciendo que las salidas no dependan sólo de las entradas actuales, sino de las entradas previas. En segundo lugar, tiene la ventaja de que la solución a un problema es menos sensible a los parámetros de la misma (número de neuronas y número de pesos). En tercer lugar, frente a otras redes realimentadas, el modelo de Elman aporta la gran ventaja de poder utilizar todos los algoritmos de entrenamiento diseñados para el MLP, más eficientes, estables y robustos que los diseñados para redes recurrentes genéricas.




Fig9 Representación de una red de Elman

Red de Hopfield

Una red de Hopfield tiene una única capa de neuronas, donde cada neurona se conecta con todas las demás, configurando una red recurrente completamente conectada, como muestra la Fig10. Este modelo neuronal presenta dos variantes, el modelo discreto y el modelo analógico o continuo, que se describen a continuación.

Modelo discreto

En el modelo discreto tanto las salidas como las entradas son valores binarios ($\{0,1\}$ o $\{-1,1\}$), mientras que los pesos $w_{i,j}$ son valores reales (continuos). El potencial de la neurona se calcula según la ecuación (22):

$$y_i(t) = f\left(\sum_j w_{i,j}x_j(t) - \theta_i\right) \quad (22)$$

donde f es la función de transferencia de las neuronas. En el proceso de ejecución de la red, en $t=0$, las neuronas reciben el valor de las entrada sx_j , calculando las salidas asociadas. Debido a las realimentaciones, las salidas se convierten en nuevas entradas en $t=1$, y así sucesivamente. En general, la dinámica de una neurona de una red de Hopfield viene dada por la ecuación (23):

$$x_i(t+1) = f\left(\sum_j w_{i,j}x_j(t) - \theta_i\right) \quad (23)$$

Esta ecuación proporciona la dinámica de una neurona de la red. Para obtener la dinámica de la red debe especificarse el orden en el que se evalúa la ecuación (23) para cada neurona, es decir, debemos decidir si todas las neuronas calculan su salida en paralelo (simultáneamente), secuencialmente (una tras otra), o de forma aleatoria. Esta ordenación se denomina dinámica de la red, y se suelen distinguir dos tipos genéricos:

- a) Dinámica asíncrona o modo serie de operación. En el instante t sólo una neurona de la red actualiza su estado. La elección de la neurona se puede hacer aleatoriamente o siguiendo un orden preestablecido.
- b) Dinámica síncrona o modo paralelo, en el que varias neuronas actualizan simultáneamente su estado en el instante t . Si todas las neuronas actualizan simultáneamente su estado estamos ante el denominado modo de operación completamente paralelo.

La aplicación de una u otra dinámica aplicada sobre la misma red hace que opere de forma diferente y que el estado final de las neuronas sea diferente.

Por ser una red realimentada, la respuesta de la red a lo largo del tiempo podrá estabilizarse, convergiendo a un estado estable, punto fijo o atractor. En otros casos, la respuesta puede no converger, describiendo las salidas una trayectoria aleatoria. Existen teoremas generales que establecen las condiciones que debe cumplir una red realimentada para que su respuesta sea estable. Una forma de hacerlo es mediante el método de Lyapunov. La función de Lyapunov se denomina también función de energía de Lyapunov debido que constituye una generalización del concepto físico de energía. Esta función permite garantizar que si se puede encontrar una función de energía para una red que disminuya con la evolución de la misma, entonces su dinámica será estable. Hopfield demostró que su modelo era estable en el caso de que la matriz de pesos sea simétrica y de diagonal nula. Esta función de energía tiene la forma de la ecuación (24):

$$E = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n w_{i,j} x_i x_j + \sum_{i=1}^n \theta_i x_i \quad (24)$$

donde debe verificarse que $w_{i,i} = 0$ y $w_{i,j} = w_{j,i}$. Por construcción, $\Delta E \leq 0$, por lo que la energía de la red nunca crece. Como consecuencia, la red siempre llegará a un estado de mínima energía que se corresponderá con un estado estable o punto fijo.

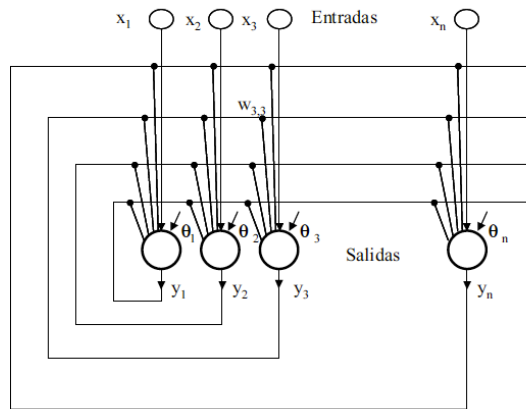


Fig10 Arquitectura de una red de Hopfield.

Determinación de los pesos

La aplicación más importante de este modelo es su utilización como memoria asociativa. En este sentido, para almacenar un conjunto de patrones se suele emplear la regla de Hebb, dada por la ecuación (25):

$$w_{i,j} = \frac{1}{n} \sum_{\mu=1}^p x_i^{\mu} x_j^{\mu} \quad (25)$$

para el caso de neuronas binarias de valores $\{-1,1\}$. En esta ecuación, p representa el conjunto de patrones. En este caso, no existe un proceso de entrenamiento como en el caso de los otros paradigmas descritos en este apéndice, sino que directamente se obtienen los valores de los pesos aplicando la ecuación (25) para un conjunto dado de patrones.

Modelo continuo

El modelo discreto de la red de Hopfield tiene el inconveniente de que las salidas únicamente pueden estar en dos estados, 0 (o -1) para neuronas inactivas y 1 para neuronas activas (o +1). Esto no se corresponde con los sistemas biológicos que inspiraron los modelos neuronales, donde las salidas de las neuronas pueden tomar cualquier valor en el intervalo $[0,1]$. Para solventar este problema, las neuronas presentan una respuesta analógica mediante el uso de la función de transferencia sigmoide dada por la ecuación (26):

$$y_i(t) = f(x) = \frac{1}{1 + e^{-\beta x}} \quad (26)$$

Al igual que para el caso discreto, para el modelo continuo puede definirse una función de energía que garantiza su estabilidad. Otra característica importante es que puede implementarse fácilmente mediante electrónica analógica, utilizando amplificadores. En este caso, la función de energía viene dada por la ecuación (27):

$$E = -\frac{1}{2} \sum_{i,j} w_{i,j} y_i y_j + \sum_i C_i \int_0^{y_i} g^{-1}(y) dy - \sum_i x_i y_i \quad (27)$$

donde C_i es una constante. Hopfield demostró que esta función no es positiva si la función g^{-1} es monótona creciente y la matriz de pesos simétrica. Cuando la función g es abrupta (ganancia elevada), los estados estables del sistema continuo y discreto coinciden si se cumple que $w_{i,j} = w_{j,i}$ y $w_{i,i} = 0$.

Determinación de los pesos

El modelo continuo de Hopfield se suele utilizar en problemas de optimización. El modelo debe basarse en la suposición de que las salidas de la red se corresponden con las variables del problema a resolver. Las condiciones o restricciones del problema deben incorporarse explícitamente como términos de la función de energía de la red. En este caso, cada valor de la función de energía se corresponde con una solución del problema. Si es posible encontrar un conjunto de pesos y entradas que formen una función de energía, dejando evolucionar a la red, ésta alcanzará un mínimo local, que representará una solución localmente óptima del problema.

REFERENCIAS

- [1] R. Lasseter, A. Akhil, C. Marnay, J. Stephens, J. Dagle, R. Guttromson, A. Sakis, R. Yinger, and J. Eto, CERTS (Construm for Electric Technology Solutions), "Integration of Distributed Energy Resources", Paper on Integration of Distributed Energy Resources, California, Octubre 2003.
- [2] R. Palma, "Redes Inteligentes en Chile-Proyecto GeVi", International Workshop on Smartgrids and Distributed Generation, Enero 2010.
- [3] J. Ng, and A. Ramadam, "Multi-Microgrid Control systems (MMCS)", IEEE Power and Energy Society General Meeting, pp. 1-6, September 2010.
- [4] C. Kieny, B. Berseneff, N. Hadjsaid, Y. Besanger, and J. Maire, "On the concept and the interest of Virtual Power Plant: some results from the European project FENIX ", IEEE PES Power & Energy Society General Meeting, pp. 1-6, France, Octubre 2009.
- [5] R. Lasseter, "Smart Distribution: Coupled microgrid", Proceedings of the IEEE, vol. 99, pp. 1074 – 1082, June 2011.
- [6] R. Palma, "Micro-redes y Sistemas Híbrido", Talleres Regionales sobre Energías Renovables no convencionales, Diciembre 2009.
- [7] F. Katiraei, R. Iravani, N. Hatzigiorgiouris y A. Dimeas, "Microgrid Mangement", IEEE power & energy magazine, vol. 6, pp. 54-65, 2008.
- [8] Department of Energy, "Federal Energy Managment Program (FEMP)", <http://www.eere.energy.gov/>
- [9] H. Rudnick, S. Mocárquer, "Recursos Renovables como Generación Distribuida en los Sistemas Eléctricos", 2005, <http://web.ing.puc.cl/power/paperspdf/morenomocarquerrudnick.pdf>
- [10] DPCA (Distribution Power Coalition of América) <http://www.energy.ca.gov/>
- [11] IEA Internacional Energy Agency, <http://www.iea.org/>
- [12] R. Palma, G. Jiménez, I. Alarcón, Gobierno de Chile, Comisión Nacional de Energía, "Las Energías Renovables No Convencionales en el Mercado Eléctrico Chileno", Marzo 2009.
- [13] T. Ackermann, G. Andersson, L. Söder, "Distributed generation a definition", ELSEVIER Electric Power Systems Research, vol. 71, pp. 119-128, October 2004.
- [14] R. Palma, J. Guillermo, I. Arias, "Las Energías Renovables no Convencionales en el Mercado Eléctrico Chileno", Publicación de la Comisión Nacional de Energía CNE, Chile, 2009.
- [15] W. Yang, A. Xin and G. Yang, "Microgrid's operation-management containing distributed generation system", IEEE International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT), pp. 703-707, July 2011.
- [16] DOE Energy Efficiency and Renewable Energy Web site provides information on energy efficiency and renewable energy technologies. U.S. <http://www.eere.energy.gov>
- [17] G. Orths and B. Eriksen, "European Test Field", IEEE PES '09 Power & Energy Society General Meeting, pp. 1-5, 2009.

-
- [18] B. Buchholz, D. Nestle, A. Kiessling, "Individual Customers Influence on the Operation of Virtual Power Plants", IEEE PES Power & Energy Society General Meeting, pp. 1-6, Alemania, 2009.
- [19] R. Palma, C. Benavides, E. Aranda, J.Llanos, D. Sáez, "Energy management system for a renewable based microgrid with a demand side management mechanism", IEEE Symposium on Computational Intelligence Applications in Smart Grid (CIASG), pp. 1-8, París, Julio 2011.
- [20] H. Dagdougui, R. Minciardi, A. Ouammi, M. Robba and R.Sacile, "A Dynamic Decision Model for the Real-Time Control of Hybrid Renewable", IEEE Systems Journal, vol 4, n. 3, pp. 323-333, 2010.
- [21] T. Logenthiran, D. Srinivasan, "Short Term Generation Scheduling of a Microgrid", IEEE Region 10 Conference TENCN 2009, pp. 1-6, 2010.
- [22] Lu, D., Francois, B. "Strategic Framework of an Energy Management of a Microgrid with a Photovoltaic-Based Active Generator", IEEE ELECTROMOTION 2009, pp.1-6, 2009.
- [23] Lagorse J., Somoes M., "A Multiagent Fuzzy-Logic- Based Energy Management of Hybrid Systems", IEEE Industry Applications Society Annual Meeting, pp. 1-7, 2008.
- [24] Tsikalakis, Hatziaargyriou, "Centralized Control for Optimizing Microgrids Operation", IEEE Transactions on Energy Conversion, vol. 23, n.1, pp. 241 - 248, 2008.
- [25] W. Brokering, R. Palma, L. Vargas, "Los Sistemas Eléctricos de Potencia", Primera Edición 2008, Editorial Pearson.
- [26] Department of Electrical Engineer Imperial College, "Demand side mangment: benefets and challenges", ELSEVIER, Jornal Energy Policy, vol. 36, n. 12, pp 4419-4426, 2008.
- [27] Programa País de Eficiencia Energética (PPEE) de la Comisión Nacional de Energía (CNE) del Gobierno de Chile, "Aprendamos a ahorrar Guía práctica de la buena energía", CNE Publicación de la Comicion Nacional de Energia, Chile, 2009.
- [28] Instituto para la Diversificación y Ahorro de la Energía (IDAE), "Guía Práctica de la Energía. Consumo Eficiente y Responsable", publicado en DAE Instituto para la Diversificación y Ahorro de la Energía, 3ª edición 2010, <http://www.idae.es/index.php/mod.publicaciones/mem.listadoDestacadas/reلمenu.73>
- [29] M. Newborough and P.augood, "Demand-side management opportunities for the UK domestic sector", IEEE Proc. Gener. Trans. Distrib, vol. 146, n. 3, 1999.
- [30] V. Hamidi, "New Control in Demand Side Management to Improve the Security of Supply in the UK's Electricity Network", IEEE Power Engineering Conference UPEC, pp. 132-137, 2007.
- [31] United Nations Industrial Development Organization (UNIDO) and the Renewable Energy and Energy Efficiency Partnership (REEEP), "Demand-side management - Modulo 14", Training Package Sustainable Energy Regulation and Policymarking for Africa, 2006, <http://africatoolkit.reeep.org/>
- [32] Y. Kim, J.Min, S. Choi, "Methods for Generating TLP (Typical Load Profiles)", IEEE Symposium on Computational Intelligence Applications In Smart Grid (CIASG), pp. 1 - 6, 2011
- [34] A. Setiawan, I. Koprinska and V. Agelidis, "Very Short-Term Electricity Load Demand Forecasting Using Support Vector Regression", IEEE International Joint Conference on Neural Networks, pp 288-2894, Georgia, Junio 2009.

-
- [35] R. Lamedica, A. Prudenzi, M. Caciotta and V. Orsolini, "The influence of Meteorological Parameters on Italian Electric Hourly Load: the Selection of Variables of the ANN Training Set for Short Term Load Forecasting", *Electrotechnical Conference*, vol. 3, Nov 1996.
- [36] K. Shanti and B. Satish, "Integrated ANN approach to forecast load", *IEEE Computer Applications in Power*, vol 15, no 2, pp. 46-51, Apr. 2002.
- [37] K. Upadhyay, M. Tripathi, and S. Singh, "An Approach to Short Term Load Forecasting Using Market Price Signal", *CIREN 19 International Conference on Electricity Distribution*, May 2007.
- [38] Z. Yun, Z. Quan, S. Caixin, L. Yuming and S. Yang, "RBF Neural Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment", *IEEE Transactions on Power Systems*, vol 23, no 3, August 2008.
- [39] H. Hippert, C. Pedreira, R. Souza, "Neural networks for short-term load forecasting: a review and evaluation", *IEEE Transactions on Power Systems*, vol. 16, no. 1, pp. 44-55, February 2001.
- [40] G. Mbamalu, M. Hawary, "Load forecasting via suboptimal seasonal autoregressive models and iteratively reweighted least squares estimation", *IEEE Transactions on Power Apparatus and Systems*, vol. 8, No. 1, February 1993.
- [41] A. Douglas, A. Breipohl, F. Lee, R. Adapa, "The impacts of temperature forecast uncertainty on Bayesian load forecasting", *IEEE Transactions on Power Systems*, vol.13, No. 13, November 1998.
- [42] R. Sadownik, and E. Pimentel, "Short-term forecasting of industrial electricity consumption in Brazil", *Journal of Forecasting*, vol. 18, No. 3, pp. 215-224, May 1999.
- [43] B. Krough, and D. Lesser, "Design and Implementation of an On-Line Load Forecasting Algorithm", *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-101, No. 9, September 1982.
- [44] N. Amjady, "Short-term hourly load forecasting using time-series modeling with peak load estimation capability", *IEEE Transactions on Power Systems* vol. 16, No. 3, August 2001.
- [45] I. Moghram, and S. Rahman, "Analysis and Evaluation of Five Short-Term Load Forecasting Techniques", *IEEE Transactions on Power Systems*, vol. 4, No. 4, October 1989.
- [46] K. Sharma, and A. Mahalanabis, "Recursive short-term load-forecasting algorithm", *PROC. IEEE*, vol. 121, No. 1, January 1974.
- [47] S. Sargunraj, D. Gupta, S. Devi, "Short-term load forecasting for demand side management", *IEEE Proceedings - Generation, Transmission and Distribution*, , vol. 144, No. 1, pp. 68-74, Jan 1997.
- [48] W. Christiaanse, "Short-Term Load Forecasting Using General Exponential Smoothing", *IEEE Transactions on Power Apparatus and Systems*, vol. PAS-90, No. 2, March 1971.
- [49] M. Hagan, S. Behr, "The Time Series Approach to Short Term Load Forecasting", *IEEE Transactions on Power Systems*, vol. 2, No. 3, Aug. 1987.
- [50] H. Yang C. Huang, "A new short-term load forecasting approach using self-organizing fuzzy ARMAX models", *IEEE Transactions on Power Systems*, vol.13, No. 1, February 1998.
- [51] W. Charytoniuk, and P. Olinda, P, "Nonparametric regression based short-term load forecasting", *IEEE Transactions on Power Systems*, vol. 13, No. 3, pp. 725-730, August 1998.

-
- [52] T. Haida, S. Muto, "Regression based peak load forecasting using a transformation technique", IEEE Transactions on Power Systems, vol. 9, No. 4, pp. 1788-1794, November 1994.
- [53] O. Hyde, and P. Hodnett, Transactions on Power Systems, IEEE "An adaptable automated procedure for short-term electricity load forecasting", vol. 12, No. 1, pp. 84-94, February 1997.
- [54] J. Toyoda, J. M. Chen Inoue, and Y. Inoue, "An Application of State Estimation to Short-Term Load Forecasting, Part I: Forecasting Modeling", IEEE Transactions on Power Apparatus and Systems, vol. PAS-89, No. 7, pp. 1678-1970, October 1970.
- [55] K. Ho, Y. Hsu, C. Chen, T. Lee, C. Liang, T. Lai and K. Chen, "Short term load forecasting of Taiwan power system using a knowledge-based expert system", vol. 5, No. 4, pp. 1214-1220, November 1990.
- [56] H. Mori, Y. Sone, D. Moridera, and T. Kondo, "Fuzzy inference models for short-term load forecasting with tabu search", IEEE International Conference on Systems, Man, and Cybernetics, 1999, vol. 6, pp. 551-556, Oct 1999.
- [57] S. Shao and Y. Sun, "Short-term load forecasting using fuzzy neural network", IEEE Fourth International Conference on Advances in Power System Control, Operation and Management, vol. 1, pp. 131-134, November 1997.
- [58] A. Khosravi, S. Nahavandi, D. Creighton, "Construction of Optimal Prediction Intervals for Load Forecasting Problems", IEEE Transactions on Power Systems, vol.25, No. 3, pp. 1496-1503, August 2010.
- [59] D. Wu, C. Aliprantis, and K. Gkritza, "Electric Energy and Power Consumption by Light-Duty Plug-In Electric Vehicles", IEEE Transactions on Power Systems, vol. 26, No. 2, pp. 738-746, May 2011.
- [61] J. Taylor and P. McSharry, "Short-Term Load Forecasting Methods: An Evaluation Based on European Data", IEEE Transaction on Power System, vol. 22, no 4, pp. 2213-2219, November 2007.
- [62] J. Cerda, R. Palma, "Estrategias de demanda a base de Generación Distribuida para una Compañía de Distribución", J. Cerda, R. Palma, 2005.
- [63] H. Chen, Y. Du y J. Jiang, "Weather Sensitive Short-Term load Forecasting Using Knowledge-Based ARX Models", IEEE Conference on Power Engineering Society General Meeting, vol.1, pp. 190-196, June 2005.
- [64] S. Jier and K. Shih, "Short-Term Load Forecasting Via ARMA Model Identification Including Non-Gaussian Process Considerations", IEEE Transaction on Power System, vol 18, no 2, pp. 673-679, May 2003.
- [65] N. Amjady, "Short-Term Hourly Load Forecasting Using Time-Series Modeling with Peak Load Estimation Capability", IEEE Transactions on Power System, vol. 16, no 3, pp. 498-505, August 2001.
- [66] J. Murillo, A. Trejos, P. Carvajal, "Estudio del pronostico de la demanda de la energía eléctrica utilizando modelos de series de", Scientia et Technica Año IX, No 23, Diciembre 2003. UTP. ISSN 0122-1701.
- [67] H. Hamadi and S. Soliman "Fuzzy short-term electric load forecasting using Kalman filter", IEEE Proc. Transm. Distrib, vol 153, no 2, pp. 217-225, March 2006.
- [68] V. Hinojosa and A. Hoese, "Short-Term Load Forecasting Using Fuzzy Inductive Reasoning and Evolutionary Algorithms", IEEE Trans. On Power System, vol 25, no 1, pp. 565-574, February 2010.
- [69] A. Setiawan, I. Koprinska and V. Agelidis, "Very Short-Term Electricity Load Demand Forecasting Using Support Vector Regression", IEEE International Joint Conference on Neural Networks, Junio 2009, Georgia, 2009, pp 288-2894.

-
- [70] E. Elattar, J. Goulermas and Q. Wu, "Electric Load Forecasting Based on Locally Weighted Support Vector Regression", IEEE Transactions on Systems, Man, and Cybernetics, vol 40, no 4, pp. 438-447, July 2010.
- [71] W. Cleveland y Devlin, "Locally weighted regression: An approach to regression analysis by local fitting", J. Amer. Statist. Assoc, vol 83, no 403, pp. 596-610, Sep 1988.
- [72] W. Chu, Y. Chen, Z. Xu and W. Lee, "Multiregion Short-Term Load Forecasting in Consideration of HI and Load/Weather Diversity", IEEE Transactions on Industry Applications, vol 47, no 1, pp. 232-237, February 2011.
- [73] K. Methaprayoon, W. Lee, P. Didsayabuttra, J. Liao, and R. Ross, "Neural network-based short term load forecasting for unit commitment scheduling", IEEE Technical Conference on Industrial and Commercial Power Systems, 2003, May 2003.
- [74] K. Methaprayoon, W. Lee, S. Rasmiddatta, J. Liao and R. Ross, "Multistage Artificial Neural Network Short-Term Load Forecasting Engine With Front-Term Weather Forecast", Transaction on Industry Applications, vol. 43, no 6, pp. 1410-1416, December 2007
- [75] J. Castellanos, A. Pazos, J. Rios, and L. Zafra, "Sensitivity analysis on neural networks for meteorological variable forecasting", in Proceedings Neural Networks for Signal Processing, 1994, pp. 554-561.
- [76] T. Senjyu, H. Takara, K. Uezato, and T. Funabashi, "One-Hour-Ahead Load Forecasting Using Neural Network", Transactions on Power Systems, vol. 17, no. 1, pp. 113-118, February 2002.
- [77] T. Senjyu, P. Mandal, K. Uezato and T. Funabashi, "Next Day Curve Forecasting Using Hybrid Correction Method", Transactions on Power Systems, vol. 20, no. 1, pp. 102-109, February 2005.
- [78] F. Yuan, M. Luung and L. Zhou, "A RBF Network for Short-Term Load Forecasting on Microgrid", IEEE International Conference on Machine Learning and Cybernetic, July 2010, Qingdao, pp. 3195-3199.
- [79] Z. Yun, Z. Quan, S. Caixin, L. Shaolan, L. Yuming, and S. Yang, "RBF Neuronal Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment", IEEE Transaction on Power System, vol. 23, no 3, pp. 853-858, August 2008.
- [80] A. Shekhar, D. Singh and S. K. Sinha, "Intelligent Hybrid Wavelet Models for Short-Term Load Forecasting", IEEE Trans. On Power System, vol 25, no 3, pp. 1266-1273, August 2010.
- [81] Y. Chen, P. Luh, C. Guan, Y. Zhao, L. Michel, M. Coolbeth, P. Friedland y S. Rourke, "Short-Term Load Forecasting: Similar Day-Based Wavelet Neuronal Network", IEEE Transaction on Power System, vol 25, no 1, pp. 322-330, February 2010.
- [82] ISO New England System Operation Procedures, Apr 4, 2007, online. http://www.iso-ne.com/rules_proceeds/operating/sysop/out_sched/index.html (sop_outsch_0040_0010.pdf).
- [83] Z. Bashird and E. Hawary, "Applying Wavelet to Short-Term Load Forecasting Using PSO-Based Neural Network", IEEE Transaction on Power Systems, vol. 24, no 1, pp. 20-27, February 2009.
- [84] C. Huang, and H. Yang, "Evolving wavelet-based networks for short-term load forecasting", IEE Proceedings-Generation, Transmission and Distribution, vol. 148, No. 3, pp. 222-228, May 2001.
- [85] M. Hanmandlu, and K. Chauhan, "Load Forecasting Using Hybrid Model", IEEE Transactions on Power Systems, vol. 26, no. 1, February 2011.
- [86] N. Amjady F. Keynia y H. Zareipour, "Short-Term Load Forecast of Microgrids by a New Bilevel Prediction Strategy", IEEE Transaction on Smart Grid, vol 1, no 3, pp. 286-294, December 2010.

-
- [87] N. Amjady and F. Keynia, "Day-Ahead Price Forecasting of Electricity Markets by Mutual Information Technique and Cascaded Neuro-Evolutionary Algorithm", IEEE Transactions on Power Systems, vol 24, no 1, pp. 306-318, February 2009.
- [88] S. Mishra and S. Kumarpatra, "Short Term Load Forecasting Using Computational Intelligence Methods", Thesis for the degree of Master of Technology in Electronics, National Institute Of Technology Rourkela, 2008.
- [89] R. Palma-Behnke, C. Benavides, E. Aranda, J. Llanos and D. Sáez, "Energy Management System for a Renewable based Microgrid with a Demand Side Management Mechanism", SSCI 2011 CIASG - 2011 IEEE Symposium on Computational Intelligence Applications in Smart Grid, Paris, France, April 11 - 15, 2011.
- [91] N. Garrido, M. Álvarez, and G. Jiménez-Estévez. A Methodological Proposal for Participation with a Community in the Development of Microgrid Projects. International Conference and Fair on Education, Research & Employment in the Renewable Energy Sector - ICERE2 2010. Santiago, 2010.
- [92] Kohonen T., Kaski S., Honkela J., Paatero V., Saarela A., "Self Organization of Massive Document Collection", IEEE Transactions on Neural Networks, vol. 11, n. 3, May 2000.
- [93] 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", IEEE Proceedings of the International Symposium Modern Electric Power Systems (MEPS), pp. 1-5, 2010.
- [94] S. Valero, J. Aparicio, C. Senabre, M. Ortiz, J. Sancho, and A. Gabaldon, "Analysis of different testing parameters in Self-Organizing Maps for short-term load demand forecasting in Spain", IEEE Proceedings of the International Symposium Modern Electric Power Systems (MEPS), pp. 1-6, 2010.
- [95] T. Kohonen, J. Kangas, "Developments and Applications of the Self- Organizing Maps and Related Algorithms", Mathematics and Computers in Simulation, pp. 5-6, 1996.
- [96] Instituto Nacional de Estadísticas (2005). CIUDADES, PUEBLOS, ALDEAS Y CASERÍOS. pp. 27. http://www.ine.cl/canales/chile_estadistico/demografia_y_vitales/demografia/pdf/cdpubaldcasjunio2005.zip. Consultado el 20 de septiembre de 2011.