

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

DISEÑO DE ESTRETEGIAS DE CONTROL PREDICTIVO ROBUSTO BASADO EN INTERVALOS DIFUSOS PARA LA OPERACIÓN DE MICRORREDES

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

JORGE IGNACIO COLLADO ARETIO

PROFESOR GUÍA: DORIS SÁEZ HUEICHAPAN

PROFESOR CO-GUÍA: FELIPE VALENCIA ARROYAVE

MIEMBRO DE LA COMISIÓN: RODRIGO PALMA BEHNKE

> SANTIAGO DE CHILE DICIEMBRE 2013

RESUMEN DE LA MEMORIA PARA OPTAR AL TITULO DE INGENIERA CIVIL ELECTRICISTA POR: JORGE COLLADO ARETIO FECHA: SEPTIEMBRE 2013

PROF. GUIA: DORIS SÁEZ H,

"DISEÑO DE ESTRETEGIAS DE CONTROL PREDICTIVO ROBUSTO BASADO EN INTERVALOS DIFUSOS PARA LA OPERACIÓN DE MICRORREDES"

Chile es un país de una geografía bastante peculiar, debido a esto existen localidades aisladas de los grandes sistemas eléctricos que proveen energía al país. Considerando además de este hecho, que el país cuenta con un potencial energético de energías renovables no convencionales importante, que no está siendo explotado. El Centro de Energía de la Universidad de Chile, ha instalado una microrred con generación distribuida que incorpora recursos renovables en la localidad de Huatacondo, ubicada en la primera región. Esta microrred está diseñada para operar con un EMS (Energy Management System), que realiza los despachos de las unidades, de manera de optimizar los costos de generación. Las entradas relevantes del EMS corresponden a predicciones de los recursos y carga de la microrred.

La finalidad de este trabajo corresponde a incorporar un nuevo enfoque en el EMS que opera actualmente en Huatancondo incorporando modelos de predicción para sus entradas que incluyan su incertidumbre. Para lograr esto se diseñaron los modelos de predicción para la potencia eólica de la microrred, ya que es la unidad de generación que presenta mayor incertidumbre dentro de la microrred por lo que sus resultados son significativos para el estudio. Este nuevo enfoque robusto para el EMS permite tomar en cuenta la incertidumbre asociada a la predicción de potencia del aerogenerador.

Se utilizaron datos históricos reales de velocidad del viento de la localidad de Huatancondo y de potencia eólica obtenida a partir de la curva de manufactura del aerogenerador de su microrred, además se contó con datos de predicción de velocidad del viento mesoescala proporcionados por el departamento de Geofísica de la Universidad de Chile. También para simular el funcionamiento de la microrred agregando los cambios propuestos, se utilizó un simulador del optimizador del EMS de la microrred de Huatacondo.

Se estudiaron modelos lineales AR, ARX y el modelo difuso TS para predecir la potencia eólica, determinando bajo el criterio del menor error cuadrático medio, que el mejor modelo para predecir la potencia del aerogenerador era el modelo TS. Luego para representar la incertidumbre del modelo de predicción seleccionado se analizaron dos técnicas para generar intervalos de confianza difusos, mediante una optimización y mediante varianza resultando más práctica para este estudio la primera.

Finalmente se aplicaron las técnicas estudiadas para diseñar un EMS robusto, para ello se aplicó la modelación TS para predicción de la potencia eólica, y a través del intervalo de confianza se determinaron nuevos despachos para el generador diesel y el banco de baterías de la microrred que reflejaran la incertidumbre de predicción.

En base a los resultados fue posible notar que efectivamente una mejora en el modelo de predicción de la potencia eólica, resulta en una optimización que obtiene menores costos ya que se acerca más a las condiciones reales. Además se pudo concluir que el enfoque robusto conlleva mayores costos, que el enfoque convencional, pero brinda una mayor seguridad, otorgándole respaldo al sistema por un aumento de costo.

Agradecimientos

En primer lugar quiero agradecer a mis padres Jorge y Francisca y a mi hermano Javier por su apoyo a lo largo de este difícil camino, en especial a mis padres quienes además de brindarme su apoyo y cariño me han otorgado todas las herramientas necesarias para poder alcanzar mis metas. Gracias por esforzarse tanto para darme siempre lo mejor.

Agradezco a mi amor Josefa por estar siempre ahí para mí, por su apoyo incondicional y por llenarme de alegría cada día dándome las fuerzas necesarias para nunca rendirme ante ninguna adversidad. Gracias por confiar siempre en mí y por llenarme de felicidad a diario.

Quiero agradecer a mis amigos de plan común quienes hicieron de mis primeros años de la universidad una grata experiencia, aunque nuestros caminos se separaron aún les guardo mucho cariño. También le agradezco mis amigos de eléctrica por siempre ayudarme con los estudios, y por los inolvidables gratos momentos fuera del ámbito universitario.

Como no agradecer a la granja un grupo de amigos que se formó en la época escolar y perdura hasta el día de hoy, gracias a todos por su amistad a lo largo de todos estos años y por todos los buenos momentos que hemos vivido juntos.

Quiero agradecer a todos los profesores de la facultad con los que me tocó instruirme a lo largo de la carrera, en especial a la profesora Doris Sáez por guiarme de forma responsable y preocupada en esta etapa final de mi carrera. También agradezco a Felipe Valencia por sus valiosos aportes en mi trabajo.

Agradezco a Fondap y Fondecyt por otorgar recursos para mi trabajo de título.

Tabla de Contenido

Índice de T	Fablas	iv
Índice de F	iguras	. v
Capítulo 1	: Introducción	. 1
1.1 N	Aotivación	. 1
1.2 0	Dbjetivos generales y específicos	. 1
Capítulo 2	: Antecedentes	. 2
2.1 N	Aicrorredes	. 2
2.2 E	Estrategias de control en microrredes	. 3
2.3 E	Energy Management system (EMS)	. 4
2.3.1	EMS centralizado	. 5
2.3.2	EMS descentralizado	. 8
2.4 F	Resumen	10
2.5 E	EMS para la microrred de Huatacondo	10
2.5.1	Función objetivo	12
2.5.2	Balance de potencias (restricciones)	13
2.5.3	Modelamiento de las fuentes de energía renovables	13
2.5.4	Modelos de predicción	14
Capítulo 3	: Modelación de la fuente eólica de la microrred de Huatacondo	15
3.1 F	Planteamiento del problema de predicción de predicción de potencia eólica	15
3.1.1	Modelos de potencia eólica	16
3.1.2	Base de datos	17
3.1.3	Evaluación de modelos	21
3.2 N	Modelación lineal para predicción de potencia eólica	22
3.2.1	Modelo autorregresivo (AR)	22
3.2.2	Modelo híbrido autorregresivo con entrada exógena (ARX)	23
3.3 N	Modelación difusa Takagi-Sugeno para predicción de potencia eólica	26
3.3.1	Modelo difuso Takagi-Sugeno	26
3.3.2	Identificación de modelos difusos Takagi-Sugeno	27
3.3.3	Identificación de modelo difuso TS para predicción de potencia eólica	29
3.4 F	Resultados: Modelación de predicción de potencia eólica	32
3.4.1	Resultados modelo AR	33
3.4.2	Resultados modelo híbrido ARX	34
3.4.3	Resultados modelo difuso TS	38
3.4.4	Resumen de resultados de modelación	41

3.5 Inclusión de la incertidumbre mediante intervalos de confianza	43
3.5.1 Intervalo de confianza basado en la covarianza del error	44
3.5.2 Intervalo de confianza utilizando optimización	45
3.6 Resultados: Intervalo de confianza	46
3.6.1 Resultados método de la covarianza difusa del error	46
3.6.2 Resultados método de optimización	50
Capítulo 4 : EMS basado en control predictivo robusto para microrred Huatacondo	53
4.1 Enfoque robusto EMS	54
4.2 Resultados	55
4.2.1 EMS convencional	55
4.2.2 Resultados EMS enfoque robusto	59
Capítulo 5 : Conclusiones	67
5.1 Trabajo futuro	68
Referencias	69

Índice de Tablas

Tabla 1: Conjuntos de datos	
Tabla 2: Desempeño datos predichos de la velocidad del viento	
Tabla 3: Iteraciones construcción modelo TS	
Tabla 4: Parámetros modelo TS	
Tabla 5: Resultados modelo AR	
Tabla 6: Resultados modelo ARX (velocidad real del viento)	
Tabla 7: Resultados modelo ARX (velocidad predicha del viento)	
Tabla 8: Resultados modelo TS (velocidad real del viento)	
Tabla 9: Resultados modelo TS (velocidad predicha del viento)	39
Tabla 10: Resultados modelación	41
Tabla 11: Resumen resultados modelación	
Tabla 12: Grado de confianza en las predicciones	49
Tabla 13: Parámetros límite inferior del intervalo	50
Tabla 14: Parámetros límite superior del intervalo	50
Tabla 15: Grados de confianza método de optimización	51
Tabla 16: Costos EMS convencional	
Tabla 17: Resultados EMS enfoque robusto	60
Tabla 18: Error medio de predicción	61
Tabla 19: Costos enfoque robusto	64

Índice de Figuras

Figura 1: Arquitectura microrred (Lasseter, 2002)	2
Figura 2: EMS Centralizado (Olivares et al., 2011)	6
Figura 3: EMS Descentralizado (Colson et al., 2011)	9
Figura 4: Google earth, ubicación Huatacondo (Fernando Lanas, 2011) 1	1
Figura 5: Diagrama de bloques EMS (Palma et al., 2012)1	1
Figura 6: Volumen del viento 1	6
Figura 7: Velocidad del viento conjunto de entrenamiento (27 de Julio del 2010 - 01 de Agosto	
del 2010)	8
Figura 8: Potencia real generada conjunto de entrenamiento (27 de Julio del 2010 -01 de Agosto	
del 2010)	9
Figura 9: Velocidad del viento conjunto de prueba (26 de Agosto del 2010 - 31 de Agosto del	
2010)	9
Figura 10: Potencia real generada conjunto de prueba (26 de Agosto del 2010 - 31 de Agosto de	l
2010)	9
Figura 11: Velocidad del viento conjunto de validación (10 de Septiembre del 2010 – 15 de	
Septiembre del 2010)	20
Figura 12: Potencia real generada conjunto de validación (10 de Septiembre del 2010 – 15 de	
Septiembre del 2010)	20
Figura 13: Error de predicción del viento2	21
Figura 14: AIC modelo AR 2	23
Figura 15: AIC modelo ARX	24
Figura 16: Errores de entrenamiento y prueba vs número de clústeres	29
Figura 17: Error de prueba vs cantidad de entradas	60
Figura 18: Predicción a 1 paso modelo AR	3
Figura 19: Predicción a 15 pasos modelo AR	\$4
Figura 20: Predicción a 96 pasos modelo AR	\$4
Figura 21: Predicción a 1 paso modelo ARX (velocidad real del viento)	\$5
Figura 22: Predicción a 15 pasos modelo ARX (velocidad real del viento)	\$5
Figura 23: Predicción a 96 pasos modelo ARX (velocidad real del viento)	6
Figura 24: Predicción a 1 paso modelo ARX (velocidad predicha del viento)	57
Figura 25: Predicción a 15 pasos modelo ARX (velocidad predicha del viento)	;7
Figura 26: Predicción a 96 pasos modelo ARX (velocidad predicha del viento)	;7
Figura 27: Predicción a 1 paso modelo TS (velocidad real del viento)	8
Figura 28: Predicción a 15 pasos modelo TS (velocidad real del viento)	;9
Figura 29: Predicción a 96 pasos modelo TS (velocidad real del viento)	;9

Figura 30: Predicción a 1 paso modelo TS (velocidad predicha del viento)	40
Figura 31: Predicción a 15 pasos modelo TS (velocidad predicha del viento)	40
Figura 32: Predicción a 96 pasos modelo TS (velocidad predicha del viento)	41
Figura 33: Comparación modelos	42
Figura 34: Resultados sintonización	46
Figura 35: Intervalo de confianza 95% a 1 paso	47
Figura 36: Intervalo de confianza 95% a 15 pasos	47
Figura 37: Intervalo de confianza 95% a 96 pasos	48
Figura 38: Intervalo de confianza 60% a 1 paso	48
Figura 39: Intervalo de confianza 60% a 15 pasos	49
Figura 40: Intervalo de confianza 60% a 96 pasos	49
Figura 41: Intervalo de confianza a 1 paso	50
Figura 42: Intervalo de confianza a 15 pasos	51
Figura 43: Intervalo de confianza a 96 pasos	51
Figura 44: Potencias reales EMS convencional	53
Figura 45: Réplicas de potencia eólica	55
Figura 46: Operación microrred EMS convencional utilizando modelo AR (Réplica 1)	57
Figura 47: Operación microrred EMS convencional utilizando modelo TS (Réplica 1)	57
Figura 48: Reserva generador diesel de situación actual	58
Figura 49: Reserva Banco de baterías de situación actual	59
Figura 50: Operación microrred EMS enfoque robusto límite inferior (Réplica 1)	62
Figura 51: Operación microrred EMS enfoque robusto límite superior (Réplica 1)	62
Figura 52: Operación generador diesel	63
Figura 53: Descarga Banco de baterías	63
Figura 54: Comparación de reservas del generador diesel	65
Figura 55: Comparación de reservas del banco de baterías	65

Glosario

CDEC: Centro de Despacho Económico de Carga
EMS: Energy Management System
GD: Generación distribuida
UC: Unit Commitment
UC-RH: Unit Commitment with Rolling horizon
MAS: Multple Agents System
MPC: Model Predictive Control
AIC: Akike Information criterion
EMC: Error medio cuadrático
AR: Autoregressive model
ARX: Autoregressive exogeneous model
TS: Modelo difuso Takagi & Sugeno
SOC: State of charge

Capítulo 1: Introducción

1.1 Motivación

Chile es un país de una geografía bastante peculiar, destacando por ser un país muy largo y angosto con 4.329 km de longitud y sólo 177 km de ancho en promedio. Según el estudio del CDEC la potencia instalada en Chile corresponde en un 60,14% a origen térmico. La geografía del país trae consigo una complicación con respecto al transporte de la energía desde su fuente de generación hasta el consumo que la requiera, debido a las extensas distancias que debe recorrer la energía para lograrlo. Si a esto se le suma la creciente demanda energética del país y su fuerte dependencia de fuentes de energía, altamente contaminantes, de origen térmico, surge la necesidad de buscar soluciones innovadoras capaces de enfrentar estas problemáticas. Una solución innovadora son las unidades de generación distribuida, las cuales se implementan directamente en la red de distribución evitándose la problemática de transmitir energía a largas distancias. Además estas por lo general son fuentes energía renovable no convencionales, aprovechando así recursos energéticos propios de la zona sin contaminar el ambiente.

Una de las formas de implementar las unidades de generación distribuida es a través de una microrred en la cual se enlazan en la red las unidades de generación, las cargas y los sistemas de almacenamiento de energía. La coordinación de todo lo antes mencionado con el objetivo de alcanzar un despacho óptimo a mínimo costo, trae consigo nuevos desafíos.

En el norte del país, el Centro de Energía de la Facultad de Ciencias Físicas y Matemáticas de la Universidad de Chile, ha implementado una microrred con GD en la localidad aislada de Huatacondo, primera región de Tarapacá. La motivación de esta memoria es el mejoramiento del EMS ya existente utilizando técnicas de control predictivo robusto.

1.2 Objetivos generales y específicos

Este trabajo de memoria tiene como objetivo general el estudio y la incorporación de incertidumbre dentro del control de microrredes mediante un control robusto, considerando la alta incertidumbre que existe en las unidades de generación distribuida.

Para lograr el objetivo general, se analizarán las opciones de modelación para predecir la potencia de generación eólica, ya que se estudiará el caso de la microrred de Huatacondo cuya unidad de generación de mayor incertidumbre resulta ser el aerogenerador, la idea es encontrar el modelo que prediga de mejor manera el fenómeno de generación de potencia eólica. Una vez estudiados los modelos se estudiaran técnicas basadas en intervalos de confianza para representar la incertidumbre presente en la predicción del modelo a utilizar de la mejor manera posible. Finalmente se propondrá un enfoque que le dé mayor robustez al EMS de la microrred.

Capítulo 2: Antecedentes

2.1 Microrredes

Para enfrentar la problemática de satisfacer la creciente demanda energética sin aumentar los niveles de contaminación del planeta, el uso de fuentes de generación distribuida aparece como una solución para suministrar, de manera confiable, una mayor cantidad de energía de origen no contaminante, sustituyendo parte de la energía de origen combustible.

El concepto de microrred, según (Lasseter, 2002), corresponde a una red de bajo voltaje, de no más de algunas decenas de kW de potencia, compuesta por un agrupamiento de cargas, unidades de generación distribuida y sistemas de almacenamiento de energía operados en coordinación para suministrar de manera confiable la energía que puede ser entregada en forma de electricidad o en forma de energía térmica. Lo que diferencia a una microrred de un sistema de potencia convencional, es que puede operar en forma autónoma pudiendo desconectarse del sistema principal si es conveniente y operar como una red independiente.

En la figura 1 se muestra un ejemplo de arquitectura de microrred (Lasseter, 2002). En ella es posible apreciar una red con sus respectivas protecciones y su ente regulador, asociada a cargas tanto eléctricas como térmicas, unidades de generación de distintos tipos y un banco de baterías. Además es posible apreciar un interruptor que une o aísla la microrred del resto del sistema, y un ente encargado de administrar la energía de acuerdo a información recibida, el cual es denominado EMS.



Figura 1: Arquitectura microrred (Lasseter, 2002)

Existen microrredes conectadas a la red principal o a otras microrredes y existen en modo aislado, estas últimas se encuentran presentes principalmente en pequeños poblados ubicados en lugares de difícil acceso, lo que convierte su conexión a la red principal en una tarea inviable. La microrred en su modo conectado, será percibida por la red principal como un elemento único capaz de responder a señales de control, sin la necesidad de conocer el funcionamiento interno de ésta, evitando la complejidad de tener que controlar cada una de las unidades de la microrred por separado además será posible el traspaso de energía a la microrred desde la red principal en caso de haber déficit y viceversa en caso de que la microrred esté generando más de lo necesario (Lasseter, 2002).

Los principales desafíos dentro de una microrred se encuentran en su versión aislada, que ocurre ante la desconexión de la red principal u otras redes, o en microrredes de naturaleza aislada. Para el correcto funcionamiento de una microrred en su estado autónomo son necesarios: un sistema de protecciones y un sistema de control siendo el segundo un gran desafío ya que se deben coordinar las diversas componentes de la microrred tomando en cuenta la información disponible y las incertidumbres asociadas a ciertas unidades de generación y a la demanda, de manera de llevar el costo de operación del sistema al mínimo posible, además de cumplir los requerimientos de potencia activa y reactiva, la tensión y la frecuencia.

2.2 Estrategias de control en microrredes

En el ámbito del control de sistemas de potencia existen dos enfoques, el centralizado y el descentralizado (Olivares, et al., 2011). El control centralizado se basa en la información reunida por un controlador central que realiza los cálculos y determina las acciones de control a aplicar todas las unidades, necesitando una compleja red de comunicación entre las unidades controladas y la central de control. En el control descentralizado cada unidad es controlada por su propia unidad de control en base a su propia información.

El control centralizado trae consigo el problema de requerir una compleja red de comunicación, lo cual se vuelve muy complejo en áreas de vasta extensión. Por otro lado el control descentralizado también acarrea problemas, ya que existe un cierto acoplamiento entre la operación de las distintas unidades, requiriéndose un cierto nivel de coordinación entre ellas y no solo de cada una localmente. Es así como es necesario un control que tome parte de ambos enfoques, este control recibe el nombre de control jerárquico (Ilic y Liu, 1996) compuesto de hasta tres niveles de control. Según la clasificación de la microrred (aislada o conectada) esta puede contar con tres niveles de control:

-Control Primario

Corresponde al primero de los niveles del control jerárquico, éste se entrega la respuesta más rápida. El control primario se encarga de la problemática de regulación de tensión y frecuencia ya que estos deben ser ajustados de forma casi instantánea para evitar efectos indeseados en la red.

-Control Secundario

El control secundario es también llamado el *Energy Management System (EMS)* es el responsable de una operación confiable, segura y económica de la microrred tanto estando aislada como conectada a la red. Este control se vuelve un verdadero desafío en microrredes aisladas con una alta presencia de fuentes de generación distribuida. El principal objetivo del EMS consiste en obtener el despacho de mínimo costo de las fuentes de generación distribuida disponibles para abastecer la demanda. Para lograr este objetivo existen tres opciones: optimización a tiempo real, sistema experto y control descentralizado jerárquico.

El control secundario corresponde al control de mayor jerarquía cuando la microrred opera como sistema aislado, y tiene una respuesta más lenta que el control primario, de esta manera desacoplando ambos controles y dándole tiempo al control secundario de realizar cálculos de mayor complejidad.

-Control Terciario

El control terciario es el de mayor nivel y fija óptimos a largo plazo dependiendo de los requerimientos de la red principal, este control es el encargado de coordinar la operación de múltiples microrredes interactuando entre sí y a su vez interactuando con la red principal. Este control puede ser considerado como externo a la microrred.

2.3 Energy Management system (EMS)

Como se dejó en claro en la sección anterior, según (Ilic y Liu, 1996) existe un control jerárquico dentro del cual el nivel secundario es el encargado de una operación confiable, óptima y económica, de la microrred. A este control secundario se le denomina EMS.

Para lograr el objetivo del EMS existen dos enfoques principales (Olivares, et al., 2011), el EMS centralizado y el EMS descentralizado. El EMS centralizado basa su funcionamiento en un controlador central mientras que el EMS descentralizado permite a interacción de las distintas unidades que conforman la microrred enfocándose en realizar una toma de decisiones descentralizada.

El EMS centralizado almacena toda la información necesaria en un lugar central, lo que permite aplicar procesos de optimización en línea. Una desventaja relevante es la dificultad que implica la inserción de nuevas unidades a la microrred, ya que significa una adaptación completa del sistema de EMS para lograrse. El EMS descentralizado en contraste presenta la gran ventaja de permitir una fácil y simple adaptación para la inclusión de nuevas unidades lo que es de gran utilidad en microrredes de mayor escala, sin embargo el no tener un sistema centralizado implica un problema de coordinación y comunicación de mayor nivel, ya que la comunicación se debe realizar hacia múltiples agentes en vez de a un solo ente central. En general el EMS centralizado es más apropiado para microrredes aisladas de pequeño tamaño, mientras que el EMS descentralizado tiene mayores ventajas en microrredes conectadas a la red y de mayor tamaño, que presentan un mayor número de unidades con múltiples dueños.

A continuación se da una explicación en mayor detalle de los enfoques centralizado y descentralizado del EMS.

2.3.1 EMS centralizado

Según (Olivares et al., 2011) y en mayor detalle en (Hatziargyriou et al., 2002, el EMS centralizado puede definirse como el agente central del sistema que reúne toda la información necesaria, proveniente de las distintas unidades de generación de la microrred, de sus cargas y de la red en sí. Además recoge las predicciones realizadas para las componentes con incertidumbre de la microrred como predicciones de carga, fuentes de generación eólica y solar que a su vez requieren predicciones de viento y solares respectivamente. Con toda esta información recolectada el EMS determina un despacho apropiado para los objetivos de la microrred. Las decisiones de este control pueden ser realizadas mediante una optimización en línea o mediante una base de datos, pre construida y constantemente actualizada, que contiene información de las condiciones de operación proveniente de cálculos fuera de línea o técnicas heurísticas.

Dependiendo de la composición de la microrred la información entrante al EMS centralizado puede ser de distinta naturaleza, pero las que principalmente están presentes son las siguientes (Olivares, et al., 2011):

- La predicción de potencia para los siguientes intervalos de tiempo proveniente de fuentes de energía inciertas, como son las fuentes de energía solar y en mayor medida las fuentes de energía eólica.
- La predicción de la demanda para los siguientes intervalos de tiempo.
- El estado de carga de los sistemas de almacenamiento de energía.
- Los límites de operación de las unidades de generación de la microrred y de sus sistemas de almacenamiento de energía.
- Las restricciones de seguridad y confiabilidad de la microrred.

• Las predicciones de precio de la energía en la red principal en caso de encontrarse la microrred interconectada con la red principal

Una vez que toda la información requerida por el EMS es reunida se da paso a un proceso de optimización para encontrar el despacho óptimo de las unidades de la microrred con el fin de minimizar la función de costo asociada de ésta. Entonces, las salidas del EMS centralizado que se obtienen son:

- Los valores de referencia para el sistema de control para cada unidad de generación, además de las decisiones de conectar o desconectar cargas interrumpibles.
- El estado para las cargas controlables (On/Off/Shift)
- UC (*unit commitment*) de los generadores despachables.

En la figura 2 se resume en un esquema el funcionamiento del EMS centralizado anteriormente explicado.



Figura 2: EMS Centralizado (Olivares et al., 2011)

Este enfoque del EMS tiene como ventaja que entrega una visión general de la microrred y una mayor sencillez en la aplicación de métodos de optimización, por otro lado sus desventajas son que requiere estar extrayendo una gran cantidad de datos constantemente para su correcto funcionamiento, y su poca flexibilidad ya que al agregarse o quitarse componentes de la microrred el EMS debe ser modificado para que vuelva a realizar su labor correctamente.

En microrredes de tamaño pequeño, con pocas combinaciones de escenarios de generación, lo más conveniente económicamente y en términos de rendimiento del sistema, es realizar cálculos

fuera de línea para obtener el óptimo de operación de los distintos escenarios. En (Hernandez-Aramburo, 2005) todos los estados de operación son analizados fuera de línea y el despacho óptimo para cada escenario es calculado y guardado para luego ser utilizado en la operación a tiempo real. A pesar de que este enfoque tiene una respuesta instantánea del sistema ante cambios, si se desea agregar fallas del sistema de distribución o una optimización de cargas térmicas, la cantidad de escenarios aumenta considerablemente. Además los sistemas de almacenamiento de energía generan dependencia del tiempo en el cálculo de despacho óptimo de la microrred, lo que lleva al problema más allá de tan solo un enfoque en escenarios. En (Pilo et al., 2007) un enfoque parecido al anterior es propuesto en el que un modelo es entrenado con resultados de flujos óptimos de potencia de múltiples escenarios factibles de la microrred. En este caso tampoco se considera el sistema de almacenamiento de energía el cual aumenta el número de escenarios y complica el proceso de optimización.

Distintos métodos de optimización han sido estudiados en la actualidad para llevar a cabo la optimización del EMS centralizado, utilizando programación lineal como se puede apreciar en (Korpas y Holen, 2006), dándole un enfoque de optimización heurística como se muestra en (Alvarez et al., 2009) o mediante una combinación de ambas como se puede observar en (Chakraborty y Simoes, 2008).

La problemática de la optimización realizada por el EMS cae en la categoría de programación no lineal mixta. La función objetivo puede incluir funciones de costo de segundo o mayor grado polinomial, además varias restricciones de cierta complejidad son incluidas para modelar los límites de operación de las unidades de la microrred. Luego agregando las restricciones asociadas a las limitantes de las líneas de la microrred, el problema de optimización adquiere un alto grado de complejidad. Para resolver este problema se han implementado técnicas de optimización heurística, incluyendo algoritmos genéticos como se puede apreciar en (Conti y otros, 2010) y (Hatziargyriou et al., 2002), PSO en (Colson et al., 2010) y *Ant colony optimization* en (Colson et al., 2009).

Además de los objetivos clásicos de optimización, se han incluido nuevos objetivos como en (Alvarez et al., 2009) y (Kanchev et al., 2010) en donde se agrega como objetivo la reducción de los gases de efecto invernadero. En este caso se utiliza una optimización multi-objetivo y se resuelve utilizando múltiples técnicas que se pueden apreciar mayor detalle en (C. Shwaegerl et al., 2011)

Como se mencionó anteriormente el sistema de almacenamiento de energía es un importante factor a estudiarse a la hora de llevar a cabo el proceso de optimización, en (Zadech et al., 2011) se puede apreciar una aplicación en la que la inclusión del sistema de almacenamiento logra una

importante reducción en el costo de operación de la microrred en comparación al caso sin considerarse.

La incertidumbre tanto en la carga como en las unidades de generación ha sido enfrentada de manera indirecta en el problema de despacho usando el enfoque MPC (*Model predictive control*), el cual consiste en una estrategia de control basada en optimización, donde un problema de optimización es formulado y resuelto para cada paso de tiempo discreto. La estrategia MPC es muy útil para el control de las microrredes ya que permite la implementación de acciones de control que anticipan eventos futuros. En una microrred aislada el MPC podría no ser suficiente para enfrentar el problema, y sería necesaria la inclusión de técnicas más detalladas para enfrentar la incertidumbre como control robusto u optimización estocástica, estas técnicas mezcladas con MPC podrían dar una buena solución en estos casos.

2.3.2 EMS descentralizado

El EMS descentralizado según (Katirae et al., 2008) busca resolver el problema de administración de la energía dándole la mayor autonomía posible a las distintas unidades de generación y a las cargas. A pesar de que puede existir intercambio de datos entre las unidades, las decisiones de control siempre son hechas de manera local. La autonomía de cada unidad se logra usando una estructura jerárquica de 3 niveles como mínimo: Operador de la red de distribución, Controlador central de la microrred y controladores locales. El operador de la red de distribución es el encargado de la interacción entre la microrred y su red de distribución y de la interconexión entre redes, es por esto que corresponde al control terciario. El controlador central de la microrred coordina la operación de las unidades de generación y las cargas, es el responsable de la operación económica y confiable. Finalmente, el controlador local controla su respectiva unidad de generación, interactuando con niveles más altos de control. En el EMS descentralizado el controlador local puede interactuar con el controlador central de la microrred y otros controladores locales para compartir cualquier información relevante para la operación de la microrred.

Las ventajas que presenta el EMS descentralizado son, que opera prácticamente de forma autónoma, no es necesario manipular cantidades grandes de datos como en el caso del EMS centralizado, otra ventaja por sobre el EMS centralizado es la flexibilidad ya que no se requieren intervenciones mayores en caso de nuevos componentes en la microrred, ya que solo entraran nuevos agentes ya sean nuevas fuentes de generación, sistemas de almacenamiento o nuevos consumos los cuales no afectan mayormente el funcionamiento global del EMS al operar de forma autónoma. La principal desventaja de este enfoque es que su aplicabilidad es casi nula en los casos de microrredes aislados de la red principal.

En la literatura actual (Olivares, et al., 2011) el EMS centralizado ha sido abordado utilizando el concepto de agentes inteligentes múltiples (*MAS*). Un *MAS* corresponde a un sistema compuesto de múltiples agentes inteligentes cada uno con información local, los cuales interactúan entre sí para lograr objetivos locales y globales, por lo que la conectividad y responsabilidad asignada a cada agente juegan un rol importante para el desempeño global de la microrred. Cada agente tiene información limitada del resto y tienen capacidad de comunicación, tienen cierto nivel de autonomía basado en sus propias metas. La teoría de estimación de estados en sistemas de potencia (Scheweppe y Wildes, 1970) puede ser utilizado para enfrentar la limitante de información de los agentes. A pesar de que los agentes pueden comunicarse, la mayoría de su coordinación es basada en su autonomía y es llevada a cabo de forma local.

El primer EMS descentralizado basado en un sistema MAS por (Colson et al., 2010), en este caso la coordinación de los agentes de la microrred se produce en un ambiente de mercado competitivo donde existen múltiples dueños de generadores. Así los componentes de la microrred son agrupados y representados por agentes que interactúan dentro de un mercado competitivo con el fin de determinar el accionar de la microrred. Específicamente los consumidores, los generadores, sistemas de almacenamiento y la red principal interactúan en este mercado ofertando precios de venta y compra al operador central de la microrred, quien basado en estas ofertas, las necesidades, restricciones y predicciones del sistema, determina la operación de las unidades de la microrred de manera de maximizar el beneficio social.

A continuación en la siguiente figura se resume gráficamente el funcionamiento del EMS descentralizado basado en MAS de mercados.



Figura 3: EMS Descentralizado (Colson et al., 2011)

Un enfoque similar de MAS es propuesto en (Logenthiram et al., 2008) donde se realizan cálculos de flujos de potencia para verificar que el despacho obtenido por el mercado cumple con las restricciones técnicas de operación.

Recientemente el enfoque de MAS con mercados se ha extendido a otras características presentes en algunas microrredes, como por ejemplo en (Logenthiran et al., 2008) donde se propone agregar nuevos agentes al mercado que representen las cargas interrumpibles con la finalidad de que todo el accionar de la microrred esté representado por diferentes señales de mercado.

El funcionamiento del EMS descentralizado en la programación de la generación se convierte en un problema de alta complejidad ya que no necesariamente todos los agentes contarán con toda la información de funciones de costo y de predicciones. Una propuesta basada en MAS es expuesta en (Zheng y Cai, 2010) el cual agrega nuevos agentes que permitan una programación adecuada para la microrred. Los agentes de servicio proveen de información de predicción y un servicio de base de datos para cada operador local.

2.4 Resumen

En resumen tanto el EMS descentralizado como el centralizado presentan ventajas y desventajas dependiendo de la microrred que se desee coordinar, para una microrred de pequeña envergadura es más conveniente un EMS centralizado debido a que el EMS descentralizado requiere de muchas unidades participantes para un mejor funcionamiento, mientras que para una microrred de mayor escala es preferible un EMS desecntralizada dada la complicada tarea de coordinar una gran cantidad de unidades desde un ente central.

2.5 EMS para la microrred de Huatacondo

En la primera región de Tarapacá se ubica Huatacondo a 230 kilómetros al sureste de la ciudad de Iquique (Figura 1), su población no supera los 100 habitantes. Es en este poblado se construyó una microrred compuesta de un sistema fotovoltaico de 22 [kW], una turbina eólica de 2.5 [kW], una unidad de generación diesel de 120 [kW], un sistema de almacenamiento de energía (ESS) de 150 [kWh] de capacidad conectado a la microrred mediante un inversor bidireccional, una bomba de agua.

La microrred de Huatacondo cuenta con un EMS (*Energy management system*) encargado de realizar las siguientes tareas:

- Minimizar el uso del diesel.
- Entregar puntos de operación para el generador diesel, el inversor del ESS y la planta fotovoltaica.

- Encender y apagar la bomba de agua para mantener el tanque de agua en los niveles predefinidos.
- Enviar señales a los consumidores promoviendo cambios de hábito en sus niveles de consumo.



Figura 4: Google earth, ubicación Huatacondo (Fernando Lanas, 2011)

Según (Palma et al., 2013). el EMS minimiza los costos de operación tomando en cuenta el almacenamiento de agua y las demandas de los consumos considera una predicción a dos días tanto de las condiciones climáticas, consumo de agua y consumo eléctrico. En la siguiente figura se resume en un diagrama de bloques el EMS propuesto que entrega la referencia de potencia para el generador diesel (P_D), la potencia para el inversor del ESS (P_I), la señal binaria para el sistema de almacenamiento de agua (B_P), la potencia solar deseada (P_S) y las señales para las cargas (S_L). Las entradas para el EMS son el máximo y el mínimo de potencia solar ($P_{S min}$, $P_{S max}$), la potencia eólica (P_E), el consumo esperado (\tilde{P}_S), consumo de agua (w_C), la condición inicial para la carga de batería (E_{SOCi}), la tensión (V_i) y corriente del banco de baterías (I_i), nivel de agua del tanque (V_{Ti}) y el estado apagado/encendido del generador diesel (B_{gi}).



Figura 5: Diagrama de bloques EMS (Palma et al., 2012)

El EMS es resuelto utilizando *unit commitment* (UC) con una estrategia de horizonte deslizante (UC-RH). El horizonte deslizante es utilizado con el fin de reducir el efecto de la aleatoriedad de las variables de entrada climáticas. Así el control UC-RH consta de los siguientes pasos (Palma et al., 2013):

1. Obtener la condición inicial para $t = t_i$

2. Optimizar la operación del sistema para los periodos desde t_i a $t_i + T$ (*T*: horizonte de predicción) usando la predicción del clima como entrada y las condiciones iniciales de las unidades. Para el caso de Huatacondo el horizonte de predicción es de 2 días, 192 pasos, con un tiempo de muestreo de 15 minutos.

3. Obtener el punto de operación óptimo de las unidades para T.

4. Aplicar los puntos de operación obtenidos en el paso 2 para un periodo menor que en *T*, en este caso para *t* a $t + \Delta$. Donde $\Delta = 16 pasos (4 horas)$.

5. Actualizar $t_i = t_i + \Delta - 1$.

6. Volver al paso 1.

2.5.1 Función objetivo

La función objetivo del EMS se utiliza para minimizar los costos de operación de la microrred en un ámbito temporal (T). La función objetivo se formula como:

$$J = \delta_t \sum_{t=1}^T C(t) + \sum_{t=1}^T C_s(t) + C_{US} \delta_t \sum_{t=1}^T P_{US}(t) + C_{Tf} \sum_{t=1}^T V_{Tf}(t) + C_H(T)$$
(2.1)

Donde δ_t es la duración del periodo hasta t, C(t) es la función de costo del generador diesel, $C_s(t)$ es la función de costo de partida del generador diesel, $P_{US}(t)$ es la potencia no abastecida en el sistema, $C_{US}(t)$ es el precio por la potencia no abastecida, $V_{Tf}(t)$ es el agua no abastecida, $C_{Tf}(t)$ es el costo por el agua no abastecida, $C_H(t)$ es el costo por utilizar el banco de baterías. Así el primer término corresponde a los costos del generador diesel, el segundo término corresponde al costo de partida del generador diesel, el tercer y cuarto término corresponden al costo de la energía no abastecida y del agua no abastecida (este término aún no ha sido implementado), finalmente el último término corresponde a la penalización por la utilización de baterías, por afectar su vida útil (este término aún es un proyecto a futuro).

2.5.2 Balance de potencias (restricciones)

El balance de potencias en la microrred debe satisfacer que:

$$P_D(t) + P_I(t) + P_{US}(t) = P_L(t) + B_P(t)\overline{P_P} - P_{Lost}(t) - P_S(t) - P_E(t)$$
(2.2)

En donde $P_L(t)$ corresponde al consumo eléctrico, $\overline{P_P}$ es la potencia de la bomba, $P_{LOST}(t)$ es la energía no utilizada proveniente de las fuentes de generación que no fue posible almacenarse.

Restricciones adicionales a este problema son que:

$$P_{US}(t) \ge 0 \tag{2.3}$$

$$P_{Lost}(t) \le 0 \tag{2.4}$$

2.5.3 Modelamiento de las fuentes de energía renovables

2.5.3.1 Panel fotovoltaico

En el modelo propuesto la energía solar es controlada por el ángulo de inclinación de este a oeste de los paneles (α). La potencia máxima $P_{Smax}(t)$ se obtiene por la óptima orientación de los paneles fotovoltaicos. En algunos casos no es factible utilizar el máximo de potencia, ya que por ejemplo las baterías se encuentran completamente cargadas. Para prevenir este problema $P_{Smin}(t)$ se obtiene cuando la inclinación de los paneles está orientada a la minina irradiancia dadas las limitaciones físicas de los paneles. Así la potencia solar $P_S(t, \alpha)$ estará dada por:

$$P_S(t,\alpha) = \eta_S A_S R_S(t,\alpha) \tag{2.5}$$

$$P_{Smin}(t) \le P_S(t,\alpha) \le P_{Smax}(t) \tag{2.6}$$

Donde η_s corresponde a la eficiencia del panel, A_s corresponde a la superficie total de la planta y $R_s(t, \alpha)$ es la irradiancia perpendicular a la superficie del panel.

2.5.3.2 Generado eólico

En general la potencia del viento puede ser obtenida a partir del perfil de viento de la turbina entregada por el proveedor. En este caso una aproximación lineal del perfil ha sido incorporada en el modelo del generador eólico.

Para obtener las predicciones de potencia del generador eólico se utilizó el perfil de viento de la turbina, además de utilizar la relación lineal existente entre la potencia y la velocidad cubica del viento. Basándose en estos dos factores se construyeron modelos para predecir la potencia en función de la velocidad cubica del viento. Finalmente utilizando predicciones mesoescala, para la velocidad del viento, facilitadas por el departamento de geofísica de la Universidad de chile, es

posible predecir la potencia generada por el aerogenerador alimentando los modelos con datos históricos y las predicciones del viento mesoescala.

2.5.4 Modelos de predicción.

2.5.4.1 Irrandiancia solar

Para la predicción de la irradiancia solar se utiliza el índice de cielo despejado (k^*) , que es una aproximación para condiciones nubosas justo encima del sensor.

$$k^*(t) = \frac{\tilde{R}_S(t)}{R_{CS}(t)} \tag{2.7}$$

Donde $\widetilde{R_S}(t)$ corresponde a la irradiancia medida, mientras que $R_{CS}(t)$ corresponde a la irradiancia calculada a partir de un modelo fenomenológico de cielo despejado. Con este modelo los errores aumentan durante la salida y puesta de sol, por lo que la ecuación anterior solo es utilizada cuando la altitud del sol es mayor a 20°. Luego para la irradiancia predicha $\widehat{R_S}(t)$, k^* se asume como un promedio de los índices del pasado.

$$\hat{R}_{S}(t+1) = R_{CS}(t+1)\frac{1}{n}\sum_{i=0}^{n-1}k^{*}(t-i)$$
(2.8)

Este modelo no es muy aceptado por los valores RMSE obtenidos en mediciones en terreno, pero dadas las especiales condiciones climáticas del norte desértico del país, el modelo es suficiente para una predicción a 2 días.

2.5.4.2 Velocidad del viento

Para la predicción de la velocidad del viento se considera un sistema global de predicción (GFS) para las condiciones de borde para un modelo climático de predicción e investigación (WRF).

El modelo GFS es utilizado para obtener las condiciones de borde que el modelo WRF utilizará como condiciones iniciales. Finalmente los resultados del modelo WRF son ajustados usando métodos estadísticos para una predicción de 12 a 48 horas.

El EMS de la microrred de Huatacondo tiene como entradas variables que cuentan con grados de incertidumbre por lo que su desempeño se ve afectado según las técnicas utilizadas para realizar estas predicciones. Es por esto que puede resultar de gran ayuda el estudio de distintos enfoques para realizar las predicciones y para modelar su incertidumbre asociada, con la finalidad de mejorar la coordinación de las unidades de la microrred a un mínimo costo.

Capítulo 3 : Modelación de la fuente eólica de la microrred de Huatacondo

3.1 Planteamiento del problema de predicción de predicción de potencia eólica

El crecimiento de la población y la industrialización han generado una creciente demanda de energía en los últimos años. Haciendo proyecciones a futuro se puede apreciar que existirá un déficit de energía en el país, si no se realizan cambios en nuestro sistema de generación de energía. En el último tiempo se han planteado soluciones para afrontar este problema, entre ellas aparece como una solución amigable con el medio ambiente las microrredes, las cuales introducen fuentes de generación distribuida como generadoras de energía, que en general son fuentes limpias y cuentan con costos de generación casi nulos ya que aprovechan al máximo el potencial energético natural de la zona. Las ventajas de las microrredes son evidentes, sin embargo también cuentan con algunos inconvenientes, como son la inestabilidad de las ERNC, dada su variabilidad y su difícil predicción. El desafío es lograr mejores modelos de predicción para este tipo de fuentes, además de incorporar su incertidumbre en el sistema de control de la red con el objetivo de lograr una solución no solo ecológica sino también segura y confiable.

En la microrred instalada en la localidad de Huatacondo descrita en 2.4, el EMS recibe como entradas tanto las predicciones de demanda como de potencia eólica y solar, dada esta y otras condiciones el EMS entrega los despachos, que minimizan la función de costo de la microrred. Si las fuentes y sus incertidumbres son modeladas de manera adecuada la inclusión de un control predictivo robusto para el EMS de la microrred puede traducirse en un control que lleve a la microrred a mejorar su operación.

La localidad de Huatacondo se encuentra ubicada en el norte del país en una zona de muy baja nubosidad, por lo que la incertidumbre presente en la radiación solar es comparativamente mucho menor a la que afecta al generador eólico producto de la variabilidad de la velocidad del viento. La velocidad de los vientos es afectada principalmente por el calor generado por la interacción de los campos electromagnéticos de la Tierra y la energía proveniente del Sol. Estos fenómenos pueden afectar la temperatura, dirección y velocidad del viento, pero éste también puede ser afectado por la altitud, la topografía del lugar donde se origina, la temperatura de la litósfera y por las pérdidas originadas acuerdo a las propiedades de la superficie. Todos estos factores involucrados en la velocidad del viento lo convierten en una variable difícil de predecir (Günter y Roth, 2003). Es por esto que para evaluar las posibles mejoras a la modelación para las predicciones de potencia y la modelación de incertidumbre se realizará con un estudio centrado en la generación eólica.

3.1.1 Modelos de potencia eólica

A pesar de no haber una linealidad directa entre la entrada del aerogenerador (velocidad del viento) y la salida (potencia eólica) se sabe que existe cierta linealidad entre la potencia eólica y el cubo de la velocidad del viento como se muestra en la siguiente deducción fenomenológica (Fernando Lanas, 2011):

La energía del viento está dada por:

$$E_{viento} = \frac{1}{2}mv^2 \tag{3.1}$$

Por lo que su energía por unidad de tiempo, es decir, su potencia viene dada por:

$$P_{viento} = \frac{E_{viento}}{t} = \frac{mv^2}{2t}$$
(3.2)

Dado que el volumen de aire que ingresa a las aspas de un aerogenerador puede ser modelado como se muestra en la figura 6:



Figura 6: Volumen del viento

Además la relación de densidad ρ , masa m y volumen V, utilizando esta relación y remplazando el volumen por el volumen descrito en la figura 6 se obtiene una expresión para la masa:

$$m = V \cdot \rho = d \cdot A \cdot \rho \tag{3.3}$$

Remplazando en la expresión para la potencia del viento se obtiene que la potencia del viento está dada por:

$$P_{viento} = \frac{1}{2} \frac{d \cdot A \cdot \rho}{t} v^2$$
(3.4)

Como la distancia por unidad de tiempo corresponde a la velocidad del viento se obtiene la siguiente expresión fenomenológica que muestra que existe linealidad entre la potencia del viento y su velocidad al cubo:

$$P_{viento} = \frac{1}{2} \rho \cdot v^3 \cdot A \left[W\right] \tag{3.5}$$

Donde, P_{viento} corresponde a la potencia del viento, ρ a la densidad del aire, v a la velocidad del viento y finalmente A corresponde al área del círculo barrido por las aspas del generador.

A pesar de que no toda la potencia del viento es transformada a potencia eléctrica, esta relación da un indicio de la linealidad que existe entre la potencia generada por el aerogenerador y el cubo de la velocidad del viento.

Dado lo anterior, se propone realizar predicciones basadas en modelos lineales de tipo AR en los que se predice la potencia solo basándose en datos pasados de la potencia, y modelos lineales híbridos de tipo ARX en los que la potencia es predicha en base a datos pasados de potencia y datos presentes y pasados del cubo de la velocidad del viento. Finalmente se realizan las predicciones basadas en la modelación difusa Takagi-Sugeno, en el cual la potencia es predicha basándose en datos pasados de potencia y datos presentes y pasados del cubo de la velocidad del viento, pero con un enfoque distinto al modelo híbrido ARX.

3.1.2 Base de datos

Para el trabajo de modelación se cuenta con datos históricos del aerogenerador en la localidad de Huatacondo dese el 27 de Julio del 2010 hasta el 26 de Septiembre del 2010. Se tienen datos de potencia generada real, velocidad del viento real y velocidad del viento predicha en este periodo. Los datos reales fueron tomados cada 15 minutos. Se cuenta con un total de datos de 5611 datos, mientras que los datos predichos fueron obtenidos a partir de predicciones mesoescala realizados cada 12 horas por el departamento de geofísica de la Universidad de Chile.

El conjunto de 5611 datos anteriormente descrito, fue dividido en tres conjuntos de datos: el conjunto de datos de entrenamiento, el conjunto de datos de prueba y el conjunto de datos de validación. El detalle de cómo fue hecha la división de estos conjuntos de datos se resume en la tabla 1.

	Conjunto de entrenamiento	Conjunto de prueba	Conjunto de validación
Duración	27 de Julio del 2010 -26 de Agosto del 2010	26 de Agosto del 2010 - 10 de Septiembre del 2010	10 de Septiembre del 2010 – 26 de Septiembre del 2010
Cantidad de datos	2806	1403	1402
% Del total de datos	~50	~25	~25

Tabla 1: Conjuntos de datos

Para analizar el comportamiento de los datos a continuación se muestran gráficamente desde las figuras 7 a la 12 los conjuntos de entrenamiento, prueba y validación respectivamente, para los primeros 500 datos o equivalentemente los primeros 7500 minutos. Como se puede observar en las figuras, los datos de velocidad predicha del viento se encuentran comparados con los datos de velocidad real del viento. Para los tres conjuntos de datos se puede apreciar la buena calidad de las predicciones ya que siguen el comportamiento general de los datos reales de la velocidad del viento donde se producen valles durante las horas correspondientes a la noche y se alcanzan los picos en las horas que corresponden al día. En cuanto a los datos de potencia real, se aprecia un comportamiento similar ya a que se producen valles y picos en los mismos intervalos de tiempo que para los datos de velocidad del viento aunque algo más pronunciados. Esto concuerda con la fenomenología del viento, ya que, como se explicó con anterioridad, la potencia del viento depende del cubo de la velocidad del viento. Así, si el viento disminuye la potencia disminuye cúbicamente y viceversa.



Figura 7: Velocidad del viento conjunto de entrenamiento (27 de Julio del 2010 - 01 de Agosto del 2010)



Figura 8: Potencia real generada conjunto de entrenamiento (27 de Julio del 2010 -01 de Agosto del 2010)



Figura 9: Velocidad del viento conjunto de prueba (26 de Agosto del 2010 - 31 de Agosto del 2010)



Figura 10: Potencia real generada conjunto de prueba (26 de Agosto del 2010 - 31 de Agosto del 2010)



Figura 11: Velocidad del viento conjunto de validación (10 de Septiembre del 2010 - 15 de Septiembre del 2010)



Figura 12: Potencia real generada conjunto de validación (10 de Septiembre del 2010 – 15 de Septiembre del 2010)

A continuación se detallan los datos predichos del viento, los cuales corresponden a predicciones mesoescala realizadas por el departamento de geofísica de la Universidad de Chile, en los cuales se obtuvieron predicciones para el viento cada 12 horas basándose en estudios del sistema de tiempo atmosférico. Calculando los errores cuadráticos para distintas predicciones.

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (v_i - \hat{v}_i)^2}$$
(3.6)

Dónde v_i corresponde al dato *i* de velocidad del viento real, \hat{v}_i al dato *i* de velocidad del viento estimada y N es el número de datos.

N° pasos de la predicción	1	24	48	72	96	120	144
Error cuadrático medio [m/s]	2.1519	2.1545	2.5229	2.5558	2.6031	2.6338	2.7100

Tabla 2: Desempeño datos predichos de la velocidad del viento

Las predicciones mesoescala son realizadas cada 12 horas, como cada paso de predicción es de 15 minutos, cada 48 pasos es realizada una nueva predicción de la velocidad del viento, es por esto que el error varía bruscamente cada 48 horas, como se puede observar en la tabla 2 donde el error se mantiene estable y aumenta en 48 luego lo mismo hasta 96 y nuevamente lo mismo hasta 144.

En la figura 13 se muestra el error de predicción para un número mayor de pasos (384 pasos, 4 días):



Figura 13: Error de predicción del viento

En la figura es posible apreciar lo que se analizó en la tabla 2 de resultados, donde dada la manera en que son hechas las predicciones, se tiene un comportamiento del error en el que se mantiene subiendo lentamente y luego sube rápidamente, esto con cierta periodicidad producto de la periodicidad con la que se hacen las predicciones (cada 12 horas).

3.1.3 Evaluación de modelos

Una vez obtenidos los modelos que se estudiarán (AR, híbrido ARX, TS) se evaluarán sus desempeños para predecir la potencia eólica en distintos horizontes de tiempo. Las predicciones se realizarán a un paso (15 minutos), a 15 pasos (3 horas y 45 minutos) y a 96 pasos (1 día). Se harán predicciones utilizando cada modelo con cada conjunto de datos, luego se compararán los errores cuadráticos medios en cada uno de los casos. El modelo que presente mejores resultados en el error de predicción será seleccionado para utilizarse en la aplicación.

3.2 Modelación lineal para predicción de potencia eólica

Los modelos lineales seleccionados para modelar el fenómeno corresponden a los modelos AR y ARX. El procedimiento para el entrenamiento de los modelos se detalla en las secciones siguientes. Para ambos procesos de entrenamiento se utilizó el índice AIC (*Akike information criterion*) para penalizar la sobreparametrización. Este índice se define a continuación:

$$AIC = \log[V\left(1 + 2\frac{m}{N}\right)] \tag{3.7}$$

Dónde m corresponde al número de parámetros estimados, N al largo de registro de datos y V representa el error medio cuadrático.

Este índice ayuda a evitar problemas debido a sobre parametrización en donde se obtienen errores bajos para el conjunto de entrenamiento pero altos para otros conjuntos de datos debido a que el modelo queda muy sobre ajustado al conjunto de entrenamiento.

3.2.1 Modelo autorregresivo (AR)

El modelo de tipo AR considera un modelo puramente autorregresivo, es alimentado solamente por sus valores pasados y considera un ruido blanco e(t). Así el modelo tiene la siguiente estructura:

$$A(z^{-1})y(t) = e(t)$$
(3.8)

Donde $A(z^{-1})$ corresponde al polinomio que representan los retardos de la salida y sus parámetros asociados:

$$A(z^{-1}) = a_0 + a_1 z^{-1} + a_2 z^{-2} \dots + a_n z^{-n}$$
(3.9)

Considerando para el caso, la potencia generada por el aerogenerador como salida del modelo se tiene el siguiente modelo AR:

$$A(z^{-1})P(t) = e(t)$$
(3.10)

Primero para determinar cuántos autorregresores usar se utilizó el índice AIC, el cual fue calculado para varios números de parámetros con el fin de encontrar el número de autorregresores más conveniente. Los resultados se muestran en la figura 14:



Figura 14: AIC modelo AR

Se puede apreciar de la figura 14 que el índice AIC es mínimo para 96 parámetros, por lo que se decide construir el modelo con 96 autorregresores (equivalente a un día anterior).

Se utilizó el método de la minimización del error cuadrático para estimas los parámetros del modelo AR, para esto se usó el conjunto de entrenamiento de potencia generada como salida.

Como se mencionó anteriormente para evaluar el modelo se utilizarán tres predicciones, la primera mirando solo un paso hacia adelante ya que es la predicción más simple, luego dado el tipo de problema se utilizará también la predicción a 96 pasos ya que como el muestreo de datos es cada 15 minutos estos 96 pasos equivalen a predecir lo que va a ocurrir con un día completo de anticipación y finalmente se elige una predicción intermedia a 15 pasos para tener una evaluación más completa del desempeño de los modelos.

La predicción a un paso queda dada por:

$$\hat{P}(t+1|t) = \theta_1 P(t) + \theta_2 P(t-1) + \dots + \theta_{96} P(t-95)$$
(3.11)

Predicción a 15 pasos:

$$\hat{P}(t+15|t) = \theta_1 \hat{P}(t+14|t) + \theta_2 \hat{P}(t+13|t) + \cdots$$

$$+ \theta_{14} \hat{P}(t+1|t) + \theta_{15} P(t) + \cdots + \theta_{96} P(t-81)$$
(3.12)

Predicción a 96 pasos:

$$\hat{P}(t+96|t) = \theta_1 \hat{P}(t+95|t) + \theta_2 \hat{P}(t+94|t) + \dots + \theta_{95} \hat{P}(t+1|t) + \theta_{96} P(t)$$
(3.13)

3.2.2 Modelo híbrido autorregresivo con entrada exógena (ARX)

Un modelo lineal se llama híbrido cuando la linealidad no existe entre las variables sino entre una variable y alguna función de la otra variable. El modelo de tipo ARX considera un modelo

autorregresivo que además es alimentado por una entrada y sus valores pasados y considera un ruido blanco e(t). Así el modelo tiene la siguiente estructura:

$$A(z^{-1})y(t) = B(z^{-1})u(t) + e(t)$$
(3.14)

Donde $A(z^{-1})$ y $B(z^{-1})$ corresponden a los polinomios que representan los retardos y parámetros de la salida y la entrada del modelo respectivamente.

$$A(z^{-1}) = a_0 + a_1 z^{-1} + a_2 z^{-2} \dots + a_n z^{-n}$$
(3.15)

$$B(z^{-1}) = b_0 + b_1 z^{-1} + b_2 z^{-2} \dots + b_n z^{-n}$$
(3.16)

Para el caso particular del generador eólico se tiene como salida la potencia y como entrada la velocidad cubica del viento, por lo que este caso es un modelo lineal híbrido en que se hace un modelo que es lineal entre la potencia y una función de la velocidad del viento. El modelo ARX híbrido quedaría de la siguiente forma:

$$A(z^{-1})P(t) = B(z^{-1})v^{3}(t) + e(t)$$
(3.17)

Al igual que para el modelo AR se obtiene el valor del índice AIC para varios números de parámetros con el fin de obtener un número adecuado de autorregresores que no sobreajuste el modelo al conjunto de entrenamiento. En la siguiente figura se muestran los resultados obtenidos para el índice:



Figura 15: AIC modelo ARX

Como es posible apreciar en la figura luego de 6 parámetros deja de bajar el índice AIC, pero también es posible detectar que hasta 5 parámetros el aporte a la calidad del modelo por la agregación de un parámetro extra es muy pequeña, luego la diferencia entre utilizar 5 y 6 parámetros es mínima, debido a esto por simplicidad se decide usar un modelo de 5 parámetros.

Utilizando el método de minimización de los mínimos cuadrados para estimar los parámetros del modelo ARX, para determinar la combinación óptima entre autorregresores de la entrada y la

salida, se probaron las combinaciones y se seleccionó la de menor error cuadrático medio. Obteniéndose el siguiente modelo híbrido:

$$P(t) = 0.6744 \cdot P(t-1) + 0.002379 \cdot P(t-2) + 0.06195 \cdot P(t-3) + 7.858 \cdot 10^{-4} \quad (3.18)$$
$$\cdot v^{3}(t) - 3.605 \cdot 10^{-4} \cdot v^{3}(t-1) + e(t)$$

A pesar de que los parámetros que acompañan a las entradas de velocidad de viento al cubo son bastante pequeños en comparación a los que acompañan a los autorregresores de potencia, esto se explica por las magnitudes de los datos de la velocidad al cubo que alcanzan valores muy superiores a los de potencia. Al ser unidades distintas uno en [m/s] y el otro en [Kw] y al no estar los datos normalizados los parámetros que las ponderan reflejan esta diferencia de unidades. Así se tiene que el modelo depende tanto de la potencia en tiempos pasadas como de las velocidades cubicas del viento a pesar de las diferencias de magnitud de los parámetros del modelo

Las predicciones con las que se evaluará el modelo quedan de la siguiente manera:

La predicción a un paso queda dada por:

$$\hat{P}(t+1|t) = 0.6744 \cdot P(t) + 0.002379 \cdot P(t-1) + 0.06195 \cdot P(t-2) + 7.858$$
(3.19)
$$\cdot 10^{-4} \cdot \hat{v}^{3}(t+1|t) - 3.605 \cdot 10^{-4} \cdot v^{3}(t)$$

Predicción a 15 pasos:

$$\hat{P}(t+15|t) = 0.6744 \cdot \hat{P}(t+14|t) + 0.002379 \cdot \hat{P}(t+13|t) + 0.06195$$

$$\cdot \hat{P}(t+12|t) + 7.858 \cdot 10^{-4} \cdot \hat{v}^{3}(t+15|t) - 3.605 \cdot 10^{-4}$$

$$\cdot \hat{v}^{3}(t+14|t)$$
(3.20)

Predicción a 96 pasos:

$$\hat{P}(t+96|t) = 0.6744 \cdot \hat{P}(t+95|t) + 0.002379 \cdot \hat{P}(t+94|t) + 0.06195 \cdot (3.21)$$
$$\hat{P}(t+93|t) + 7.858 \cdot 10^{-4} \cdot \hat{v}^3(t+96|t) - 3.605 \cdot 10^{-4} \cdot \hat{v}^3(t+95|t)$$

Es posible notar que a diferencia de las predicciones del modelo AR, donde hasta un día siempre las predicciones dependen de al menos un dato real, en el modelo híbrido ARX las predicciones a mayores pasos pasan a depender solo de predicciones anteriores, sin ser alimentadas por algún dato real.

3.3 Modelación difusa Takagi-Sugeno para predicción de potencia eólica

3.3.1 Modelo difuso Takagi-Sugeno

En (Sáez y Cipriano, 2001) se define un modelo difuso TS como un modelo no lineal autorregresivo con variable exógena, cuya estructura es de la siguiente forma:

$$y(k) = f(x(k))$$
 (3.22)

$$x(k) = \begin{bmatrix} y(k-1) \\ \vdots \\ y(k-na) \\ u(k-nk) \\ \vdots \\ u(k-nk-nb) \end{bmatrix} = \begin{bmatrix} x_1 \\ \vdots \\ x_{na} \\ x_{na+1} \\ \vdots \\ x_{na+nb} \end{bmatrix}$$
(3.23)

Donde y(k) es la variable de salida, f una función no lineal, x(k) es el vector de las variables de entrada del modelo y u(k) corresponde a la entrada del proceso. La función no lineal f en los modelos difusos TS corresponde a:

$$Si \ y(k-1) \ es \ A_{1}^{r} \ y \dots y \ y(k-na) \ es \ A_{na}^{r} \ y \dots y \ u(k-nk) \ es \ A_{na+1}^{r} \ y \dots y \\ u(k-nb-nk) \ es \ A_{na+nb}^{r}$$

$$entonces \ y_{r}(k) = g_{0}^{r} + g_{1}^{r} y(k-1) + \dots + g_{na+nb}^{r} u(k-na) + g_{na+1}^{r} u(k-nk) + \dots + g_{na+nb}^{r} u(k-nk-nb)$$
(3.24)

Donde A_i^r son conjuntos difusos, g_i^r son los parámetros de las consecuencias y $y_r(k)$ es la salida de la regla r. En este caso las variables de entrada de las premisas de cada regla son combinadas utilizando operadores lógicos "y", y las variables de salida dadas por modelos lineales, consideran distintas regiones de operación. La salida del modelo difuso TS es determinada dándole distintos pesos a la salida de cada regla $y_r(k)$, mediante su grado de activación w_r , como se muestra a continuación:

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r}$$
(3.25)

Donde N_r corresponde al número de reglas y el grado de activación w_r está dado por:

$$w_r = \mu_1^r \dots \mu_i^r \dots \mu_{na+nb}^r \tag{3.26}$$

Donde μ_i^r corresponde al grado de pertenencia del conjunto difuso A_i^r . La función de pertenencia utilizada en los modelos difusos para esta aplicación corresponde a:

$$\mu_i^r = e^{\frac{-1}{2}(a_i^r(x_i - b_i^r)^2)} \tag{3.27}$$

Donde a_i^r y b_i^r son parámetros de las funciones de pertenencia y x_i es una variable de entrada del modelo.

3.3.2 Identificación de modelos difusos Takagi-Sugeno

Para la identificación de un modelo difuso Takagi-Sugeno es necesario determinar el número de clusters y las entradas más relevantes para obtener las salidas de cada regla. Para lograr esto se utilizan dos métodos, la comparación entre los errores cuadráticos medios utilizando los conjuntos de prueba y de entrenamiento para determinar el número de clusters y el análisis de sensibilidad para determinar las entradas más relevantes para el modelo.

En la comparación ente el error cuadrático medio de prueba y de entrenamiento lo que se hace es obtener el error cuadrático medio utilizando el conjunto de entrenamiento y el conjunto de prueba para el modelo difuso TS para varios números de clusters, luego se grafican la curva de error de prueba y error de entrenamiento versus el número de clusters y se elige como el número de clusters a utilizar el número que minimice el error de prueba sin que aumente el error de entrenamiento.

El análisis de sensibilidad según (Sáez y Cipriano, 2001) corresponde a un método novedoso para determinar qué variables se deben utilizar en el modelo. En este método se inicia con la máxima cantidad de variables de entrada candidatas para el modelo, las cuales son determinadas por conocimiento del proceso. Cada variable de entrada es normalizada para evitar la influencia de las diferencias de magnitud de las entradas candidatas. Luego se calcula el índice de sensibilidad para cada variable de entrada. La sensibilidad de la variable entrada ξ_i se define como:

$$\xi_i(x) = \frac{\partial f(x)}{\partial x_i} \tag{3.28}$$

Donde *f* corresponde a la función no lineal del modelo difuso TS y x_i corresponde a las variables de entrada del modelo. La sensibilidad de la variable de entrada corresponde a su relevancia con respecto a la salida del modelo difuso. Realizando el proceso de derivación correspondiente se obtiene una expresión para obtener $\xi_i(x)$.

$$\xi_i(x) = \frac{\sum_{r=1}^{N_r} (w_r c_i^r y_r + g_i^r w_r) \sum_{r=1}^{N_r} w_r - \sum_{r=1}^{N_r} (w_r c_i^r) \sum_{r=1}^{N_r} w_r y_r}{(\sum_{r=1}^{N_r} w_r)^2}$$
(3.29)

Donde:

$$c_i^r = -(a_i^r(x_i - b_i^r))a_i^r (3.30)$$

Finalmente habiendo calculado $\xi_i(x)$ se calcula su media aritmética y su desviación estándar, para calcular el índice de sensibilidad asociado a la entrada como:

$$I_i = \mu_i^2 + \sigma_i^2 \tag{3.31}$$

Así teniendo los índices de todas las entradas candidatas se eliminan las entradas de menor relevancia utilizando un umbral o eliminando la entrada de menor relevancia en cada iteración.

A continuación se definen los pasos a seguir utilizando estos métodos para poder finalmente encontrar el modelo TS que se acerque más al número óptimo de clusters y entradas del modelo.


Finalmente se obtiene un número de clusters que minimiza el error de prueba sin aumentar el error cuadrático medio de entrenamiento, y se obtienen las entradas más relevantes para la salida del modelo difuso que no aumentan el error de prueba para el modelo difuso TS.

3.3.3 Identificación de modelo difuso TS para predicción de potencia eólica

Para la identificación del modelo difuso TS, se utilizaron como variables candidatas los cinco primero autorregresores de la potencia, además de la velocidad cubica del viento y sus cuatro primeros autorregresores. Esta elección fue llevada a cabo basándose en el modelo lineal ARX anteriormente obtenido, el cual consideraba 3 autorregresores de potencia un autorregresor del cubo de la velocidad del viento y el cubo de la velocidad del viento en el tiempo actual. Por lo tanto se escogieron más autorregresores tanto para la salida como para la entrada que los identificados en el modelo ARX de manera de contar con cierta holgura, así el modelo final de TS debería utilizar algún número de entradas menor a las entradas candidatas con las que se está comenzando.

$$x_{candidatas} = \begin{bmatrix} P(t-1) \\ \vdots \\ P(t-5) \\ v^{3}(t) \\ \vdots \\ v^{3}(t-4) \end{bmatrix}$$
(3.32)

Luego se realizaron tanto la comparación de los errores cuadráticos medios utilizando los conjuntos de prueba y de entrenamiento como el análisis de sensibilidad para varias iteraciones. Obteniéndose los siguientes resultados en la última iteración con los que se construirá el modelo:



Figura 16: Errores de entrenamiento y prueba vs número de clústeres



Figura 17: Error de prueba vs cantidad de entradas

El paso 1 del procedimiento fue definir el conjunto de variables candidatas para el modelo TS, luego el paso 2 realizar la comparación entre el error cuadrático medio utilizando los conjuntos de prueba y de entrenamiento variando el número de clusters, el paso 3 obtener los índices de sensibilidad para las variables del modelo de entrada y eliminar la de menor relevancia en el paso 4, en el paso 5 se obtiene el error de prueba para el modelo habiendo determinado en los pasos anteriores el número de clústeres y las variables de entrada más relevantes, finalmente en el paso 6 se vuelve a iterar desde el paso 2 hasta llegar al modelo más simple (de una sola entrada). En la tabla 3 se muestra en la primera columna las iteraciones hasta llegar al modelo que resultó ser el de mejores resultados (se hicieron más iteraciones pero no son relevantes), en la segunda columna se muestran los resultados del paso 2 para cada iteración, en la columna tres se muestra que variable de entrada fue eliminada para el paso 4 de su iteración correspondiente, finalmente en la cuarta columna se observan las variables de entrada del modelo TS que quedan al final de cada iteración. En la figura 17 que muestra los errores de prueba en función de la cantidad de entradas se aprecia que el modelo de menor error cuadrático para el conjunto de prueba corresponde al de la sexta iteración.

En la tabla 3 se resumen las iteraciones realizadas.

N° Iteración	N° de clústeres	Variable de entrada eliminada (la de menor índice de sensibilidad)	Variables de entrada restantes en el modelo	RMS prueba
1	4	$v^{3}(t-4)$	$P(t-1), P(t-2), P(t-3), P(t-4), P(t-5), v^{3}(t), v^{3}(t-1), v^{3}(t-2), v^{3}(t-3)$	0.9156
2	4	P(t - 5)	$P(t-1), P(t-2), P(t-3), P(t-4), v^{3}(t), v^{3}(t-1), v^{3}(t-2), v^{3}(t-3)$	0.9723
3	4	P(t-4)	$P(t-1), P(t-2), P(t-3), v^{3}(t), v^{3}(t-1), v^{3}(t-2), v^{3}(t-3)$	0.8661
4	4	$v^{3}(t-3)$	P(t-1), P(t-2), P(t-3), $v^{3}(t), v^{3}(t-1), v^{3}(t-2)$	0.6747
5	4	P(t-3)	P(t-1), P(t-2), $v^{3}(t), v^{3}(t-1), v^{3}(t-2)$	0.6533
6	2	$v^{3}(t-2)$	$P(t-1), P(t-2), \\ v^{3}(t), v^{3}(t-1)$	0.2720

Tabla 3: Iteraciones construcción modelo TS

Luego de realizarse todo el procedimiento de identificación se obtiene que el vector de entrada para el modelo TS está dado por:

$$x = \begin{bmatrix} P(t-1) \\ P(t-2) \\ v^{3}(t) \\ v^{3}(t-1) \end{bmatrix}$$
(3.33)

En la figura 16 de errores de prueba y de entrenamiento vs número de clústeres se puede apreciar que el número más adecuado de clústeres es cuatro, sin embargo dado que el error para 2 clústeres es similar, por simplicidad se decide utilizar solo 2 clusters.

Finalmente se construye el modelo difuso utilizando los conjuntos de datos de entrenamiento para las entradas obtenidas y el número de clusters obtenido. El modelo difuso TS se resume a continuación:

$$\hat{P}(t) = f^{TS}(P(t-1), P(t-2), v^3(t), v^3(t-1))$$

$$i si P(t-1) es A_i^1 + v P(t-2) es A_i^2 + v v^3(t-1) es A_i^3 + v v^3(t-1) es A_i^4$$

$$(3.34)$$

$$R_{j} si P(t-1) es A_{j}^{1} y P(t-2) es A_{j}^{2} y v^{3}(t-1) es A_{j}^{3} y v^{3}(t-1) es A_{j}^{4}$$

entonces $P_{j}(t) = g_{0}^{j} + g_{1}^{j} P(t-1) + g_{2}^{j} P(t-2) + g_{3}^{j} v^{3}(t) + g_{4}^{j} v^{3}(t-1)$

$$(3.35)$$

j	g_0^j	g_1^{j}	g_2^j	g_3^{j}	g_4^{j}
1	1.4319	0.2128	0.0416	$6.4625 \cdot 10^{-4}$	$-1.3375 \cdot 10^{-4}$
2	-0.0249	0.1711	0.0030	0.0027	$-3.9361 \cdot 10^{-4}$

Tabla 4: Parámetros mo	odelo TS
------------------------	----------

Las predicciones para luego evaluar el modelo quedan de la siguiente forma:

A 1 paso:

$$\hat{P}(t+1|t) = f^{TS}(P(t), P(t-1), \hat{v}^3(t+1|t), v^3(t))$$
(3.36)

A 15 pasos:

$$\hat{P}(t+15|t) = f^{TS}(\hat{P}(t+14|t), \hat{P}(t+13|t), \hat{v}^3(t+15|t), \hat{v}^3(t+14|t))$$
(3.37)

A 96 pasos:

$$\hat{P}(t+96|t) = f^{TS}(\hat{P}(t+95|t), \hat{P}(t+94|t), \hat{v}^{3}(t+96|t), \hat{v}^{3}(t+95|t)$$
(3.38)

3.4 Resultados: Modelación de predicción de potencia eólica

Para la evaluación de resultados se utilizó el error cuadrático medio:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (P_i - \hat{P}_i)^2}$$
(3.39)

Dónde P_i corresponde al dato *i* de la potencia eólica real, \hat{P}_i al dato *i* de la potencia eólica estimada y *N* representa el número de datos.

Se evaluó el error cuadrático medio para predicciones de un paso, 15 pasos y 96 pasos, utilizando el conjunto de entrenamiento, de prueba y de validación, tanto para la velocidad del viento real como para la predicción mesoescala realizada por el departamento de geofísica en los casos del modelo ARX y TS.

3.4.1 Resultados modelo AR

En la tabla 5 se muestran los resultados obtenidos con el modelo AR $A(z^{-1})P(t) = e(t)$, utilizando la velocidad real del viento.

Error cuadrático medio [kW]					
Conjunto de datos	Predicción a 1 paso (15 min)	Predicción a 15 pasos (3 hrs 45 min)	Predicción a 96 pasos (1 día)		
Entrenamiento	0.5211	0.8617	0.8975		
Prueba	0.6593	1.1841	1.1886		
Validación	0.5364	0.8978	0.9184		

Tabla 5: Resultados modelo AR

A continuación se muestran los resultados obtenidos por el modelo AR para cada predicción utilizando el conjunto de validación, en las figuras 18,19 y 20 se pueden apreciar comparativamente el modelo AR y los datos reales de potencia. En el caso de la predicción a un paso se puede observar un comportamiento aceptable del modelo con errores bajos, sin embargo, tanto en la predicción a quince pasos como en la predicción a 96 pasos el modelo AR baja su certeza de predicción, observándose en las figuras 18,19 y 20 errores grandes en ciertos instantes de tiempo. Esto se puede explicar por la naturaleza de los modelos AR los cuales son solo alimentados por la información de tiempos pasados de la salida. Debido a esto el modelo se vuelve menos eficiente al predecir a más pasos hacia el futuro ya que el modelo AR cuenta con menos datos recientes reales sobre las salidas, así los datos de mayor relevancia para el modelo son también predicciones, lo que produce que el error aumente drásticamente.



Figura 18: Predicción a 1 paso modelo AR



Figura 19: Predicción a 15 pasos modelo AR



Figura 20: Predicción a 96 pasos modelo AR

3.4.2 Resultados modelo híbrido ARX

A continuación se muestran los resultados obtenidos con el modelo híbrido ARX utilizando la velocidad real del viento:

Error cuadrático medio [kW] (velocidad real del viento)					
Conjunto de datos	Predicción a 1 paso (15 min)	Predicción a 15 pasos (3 hrs 45 min)	Predicción a 96 pasos (1 día)		
Entrenamiento	0.4069	0.5993	0.6563		
Prueba	0.4736	0.6538	0.7943		
Validación	0.4141	0.6775	0.7952		

Tabla 6: Resultados modelo ARX (velocidad real del viento)

A continuación se muestran los resultados obtenidos por el modelo ARX para cada predicción utilizando el conjunto de validación y la velocidad real del viento. En las figuras 21, 22 y 23 se pueden apreciar comparativamente el modelo ARX y los datos reales de potencia. Es posible observar que la predicción a un paso se acerca mucho a los datos reales excepto en los dos

primeros picos de potencia en donde el modelo ARX alcanza valores mucho mayores que la potencia real, este problema también se puede observar en las predicciones a 15-96 pasos. En base a los resultados se puede plantear la teoría de que las mediciones de viento, en los dos primeros picos de potencia, son erradas ya que el modelo tiene buenos resultados en estos instantes para la predicción de viento, y buenos resultados para todo el resto del tiempo, lo que significa que el problema no es del modelo sino que los datos de velocidad del viento real medidos en esos instantes ya que no concuerdan con la potencia real medida. A diferencia del modelo AR el modelo ARX tiene un aumento del error menos marcado al realizarse predicciones a más pasos, esto se debe a que el modelo ARX no solo depende de valores pasados de la salida, sino también es alimentado por valores presentes y pasados de su entrada lo que lleva a no heredar los errores de predicción a las predicciones a más pasos al alimentarse de dos fuentes de información distintos.



Figura 21: Predicción a 1 paso modelo ARX (velocidad real del viento)



Figura 22: Predicción a 15 pasos modelo ARX (velocidad real del viento)



Figura 23: Predicción a 96 pasos modelo ARX (velocidad real del viento)

En la tabla 7 se muestran los resultados obtenidos con el modelo ARX utilizando la velocidad predicha del viento:

Error cuadrático medio [kW] (velocidad predicha del viento)					
Conjunto de detos	Predicción a 1 paso (15	Predicción a 15 pasos (3	Predicción a 96 pasos (1		
Conjunto de dutos	min)	hrs 45 min)	día)		
Entrenamiento	0.5334	0.8507	0.8940		
Prueba	0.6612	1.1658	1.2556		
Validación	0.5147	0.7530	0.9003		

 Tabla 7: Resultados modelo ARX (velocidad predicha del viento)

En las figuras 24,25 y 26 se muestran los resultados obtenidos con el modelo ARX utilizando la velocidad predicha del viento y el conjunto de validación. Estos resultados son importantes debido a que en la práctica se utilizan datos predichos de la velocidad cubica del viento ya que no se puede medir el futuro. Como se mencionó anteriormente ya no existe el problema de los datos reales del viento errados en los dos primeros picos de potencia. Aunque, como era de esperarse, el desempeño del modelo se reduce comparativamente con su desempeño utilizando datos reales de la velocidad del viento puesto que el error también refleja el error de predicción del viento. En general los resultados fueron similares a los del modelo ARX con datos reales de viento, sin embargo, con errores de predicción mayores debido a los errores de predicción del viento.



Figura 24: Predicción a 1 paso modelo ARX (velocidad predicha del viento)



Figura 25: Predicción a 15 pasos modelo ARX (velocidad predicha del viento)



Figura 26: Predicción a 96 pasos modelo ARX (velocidad predicha del viento)

3.4.3 Resultados modelo difuso TS

A continuación se muestran los resultados obtenidos con el modelo difuso TS utilizando la velocidad real del viento:

Error cuadrático medio [kW] (velocidad real del viento)					
Conjunto de datos	Predicción a 1 paso (15	Predicción a 15 pasos (3 brs 45 min)	Predicción a 96 pasos (1		
	11111)		ula)		
Entrenamiento	0.2345	0.2540	0.3805		
Prueba	0.2720	0.2977	0.5579		
Validación	0.3059	0.3489	0.6022		

Tabla 8: Resultados modelo TS (velocidad real del viento)

En este caso salvo por los errores de los datos de velocidad del viento mencionados anteriormente, el modelo tiene un muy buen desempeño muy superior a los modelos AR y ARX obteniéndose errores hasta cuatro veces menores, además otro punto a favor del modelo TS es que en cuanto al aumento del error con respecto al aumento del número de pasos de la predicción, el modelo TS varía muy lentamente su error aumentando en muy poca medida, esto se debe a su bajo error de predicción a un paso lo que se traduce en un arrastre de error de predicción muy bajo hacia las predicciones futuras, es decir, como las predicciones con el modelo TS se acercan mucho a los datos reales de potencia, las predicciones a más pasos que utilicen estas predicciones se verán afectadas en menor medida.



Figura 27: Predicción a 1 paso modelo TS (velocidad real del viento)



Figura 28: Predicción a 15 pasos modelo TS (velocidad real del viento)



Figura 29: Predicción a 96 pasos modelo TS (velocidad real del viento)

En la tabla 9 se muestran los resultados obtenidos con el modelo difuso TS utilizando la velocidad predicha del viento:

Error cuadrático medio [kW] (velocidad predicha del viento)					
Conjunto de datos	Predicción a 15 pasos (3 hrs 45 min)	Predicción a 96 pasos (1 día)			
Entrenamiento	0.5692	0.6307	0.6894		
Prueba	0.8990	1.0298	1.1282		
Validación	0.5036	0.5428	0.7343		

Tabla 9: Resultados modelo TS (velocidad predicha del viento)

En las figuras 30, 31 y 32 se muestran los resultados obtenidos con el modelo difuso TS utilizando la velocidad predicha del viento y el conjunto de validación. Los resultados se ven

afectados por el error de predicción de la velocidad del viento, sin embargo el modelo sigue siendo superior a los modelo AR y ARX inclusive si se le compara con los resultados de éstos utilizando datos reales de velocidad del viento, lo que demuestra una superioridad en cuanto al error cuadrático medio en los resultados del modelo TS comparado con los modelos AR y ARX. Además el modelo conserva la característica de gran utilidad para esta aplicación que es no empeorar en gran medida las predicciones al hacer predicciones a más pasos.



Figura 30: Predicción a 1 paso modelo TS (velocidad predicha del viento)



Model TS utilizando velocidad predicha del viento, predicción a 15 pasos

Figura 31: Predicción a 15 pasos modelo TS (velocidad predicha del viento)



Figura 32: Predicción a 96 pasos modelo TS (velocidad predicha del viento)

3.4.4 Resumen de resultados de modelación

Para poder elegir el mejor modelo de los estudiados para la aplicación requerida, se muestra un resumen general de los resultados en la tabla 10 y en la figura 33 es posible observar gráficamente la comparación de los 3 modelos.

	Error cuadrático medio [kW]				
	Conjunto de datos	Predicción a 1 paso (15 min)	Predicción a 15 pasos (3 hrs 45 min)	Predicción a 96 pasos (1 día)	
0	Entrenamiento	0.5211	0.8617	0.8975	
odel AR	Prueba	0.6593	1.1841	1.1886	
Μ	Validación	0.5364	0.8978	0.9184	
0 0	Entrenamiento	0.4069	0.5993	0.6563	
lodel Íbrid ARX	Prueba	0.4736	0.6538	0.7943	
Z H '	Validación	0.4141	0.6775	0.7952	
TS	Entrenamiento	0.2345	0.2540	0.3805	
delo	Prueba	0.2720	0.2977	0.5579	
Mo	Validación	0.3059	0.3489	0.6022	

Tabla 10: Resultados modelación

En la tabla 10 que resume los resultados, se muestran los errores de cada modelo para cada conjunto utilizando el cubo de la velocidad real del viento. Es posible apreciar que el modelo TS obtiene un menor error cuadrático medio que los modelos AR e híbrido ARX en todo conjunto de datos y para todas las predicciones.



Figura 33: Comparación modelos

En la figura 33 se utilizó una ventana de tiempo de 50 horas para apreciar las diferencias entre los modelos. La construcción de todos los modelos se realizó con datos de potencia de validación y datos de velocidad real del viento al cubo de entrenamiento. Además las predicciones fueron hechas a 96 pasos. Se puede observar que el modelo AR sigue la tendencia general de la potencia real, sin embargo, siempre con un error cuadrático medio mayor al resto de los modelos. El modelo híbrido ARX si logra seguir la tendencia real, pero siempre con un error mayor que el modelo TS que logra una muy buena predicción siendo casi imperceptible su error en algunos tramos a simple vista.

En la tabla 11 se resumen las ventajas y desventajas para los tres modelos estudiados AR, ARX y TS. Para esto se comparan las ventajas y desventajas obtenidas para cada modelo a partir de los resultados obtenidos cuyo detalle se encuentra en las tablas de los resultados particulares.

	Ventajas	Desventajas
Modelo AR	No requiere de mediciones ni predicciones del viento. Modelación simple.	Error de predicción alto, el error crece con el aumento del número de pasos de predicción.
Modelo ARX	Modelación simple, mejores resultados en el error de predicción que modelo AR, el error crece menos que el modelo AR al aumentar el número de pasos de predicción.	Requiere de datos de la velocidad del viento. El error de predicción es mayor que en el modelo TS y crece más bruscamente al aumentar el número de pasos de predicción que el TS.
Modelo TS	Error de predicción menor que para los modelos AR y ARX, su error crece menos que los demás modelos estudiados a medida que se aumenta el número de pasos de predicción.	Modelación de mayor complejidad que los modelos AR y ARX. Requiere de datos de velocidad del viento.

Tabla 1	11:	Resumen	resultados	modelación
---------	-----	---------	------------	------------

Finalmente dadas las ventajas y desventajas de cada uno de los tres modelos estudiados como el propósito de los modelos es poder predecir potencia eólica teniendo tanto datos de la velocidad

del viento como de potencia medida, es claro que el modelo TS es el más adecuado. Ya que su única desventaja comparativa con los modelos AR y ARX es su grado de complejidad de modelación mayor, pero a pesar de ser mayor no es de una complejidad tan alta que dificulte su implementación, por lo que el modelo TS será el modelo a utilizarse para realizar los estudios de predicción de potencia eólica.

3.5 Inclusión de la incertidumbre mediante intervalos de confianza

El paso a seguir luego de concluida la identificación del modelo difuso, es encontrar un intervalo de confianza que modele correctamente la incertidumbre del modelo. El enfoque que se le da en este caso a los intervalos de confianza es el de intervalos de confianza difusos en el que los límites superiores e inferiores también son funciones de tipo difuso que cumplen que:

$$f(z_i) \le g(z_i) \le \overline{f}(z_i) \tag{3.40}$$

En donde $\underline{f}(z_i)$ y $\overline{f}(z_i)$ corresponden a las funciones difusas del límite inferior y superior del intervalo de confianza respectivamente, y $g(z_i)$ corresponde a la función del modelo difuso que estima la salida.

Para aplicar el concepto de intervalos de confianza difusos al caso de la predicción de potencia eólica modelada con un modelo difuso TS, se utilizaron dos distintos métodos, uno utilizando la covarianza del error de estimación del modelo y el otro realizando una optimización en torno a los parámetros de las funciones difusas que definen los límites del intervalo de confianza.

Para ambos enfoques se utiliza la notación para modelos difusos que se muestra a continuación:

Se sabe que la salida de un modelo difuso está dada por:

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r}$$
(3.41)

Si se define β_r como:

$$\beta_r = \frac{w_r}{\sum_{r=1}^{N_r} w_r} \tag{3.42}$$

Entonces la salida del modelo difuso puede escribirse de la siguiente forma:

$$y = \sum_{r=1}^{N_r} \beta_r \, y_r \tag{3.43}$$

Como y_r corresponde a una función lineal de las entradas del modelo difuso $x = [x_1, ..., x_n]$ entonces y_r puede anotarse como:

$$y_r = [1, x]\theta_r \quad con \quad \theta_r = [\theta_{r0}, \theta_{r1} \dots \theta_{rn}] \tag{3.44}$$

Y así la salida del modelo queda como:

$$y = \sum_{r=1}^{N_r} \psi_r^{\ T} \theta_r \tag{3.45}$$

 $\operatorname{Con} \psi_r^{\ T} = \beta_r[1, x]$

Así finalmente definiendo las matrices de parámetros de las consecuencias como $\Theta^T = [\theta_1, ..., \theta_{N_r}]$ y de regresión difusa como $\Psi^T = [\psi_1^T, ..., \psi_{N_r}^T]$, se tiene la siguiente expresión matricial para la salida del modelo:

$$y = \Psi^T \Theta \tag{3.46}$$

3.5.1 Intervalo de confianza basado en la covarianza del error

Para encontrar las funciones difusas que definan los límites del intervalo de confianza se debe entender que lo que se desea, es encontrar un intervalo que sea lo más acotado posible, pero que contenga un cierto porcentaje de datos. Para lograr este objetivo este método (Škrjanc, 2011) plantea utilizar la covarianza del error para definir las funciones difusas de los límites del intervalo de confianza. En el siguiente desarrollo se obtienen las expresiones que definen las funciones difusas del intervalo de confianza.

La salida medida para el k-esimo modelo local está definida por (Škrjanc, 2011):

$$y_k = \psi_k^{\ T} \theta_k + e_k \tag{3.47}$$

La salida del modelo para el k-esimo modelo local está dado por:

$$\hat{y}_k = \psi_k^{\ T} \hat{\theta}_k \tag{3.48}$$

En este método para encontrar el intervalo de confianza es necesario obtener la covarianza del error de predicción, para definir en función de estos los límites del intervalo.

$$cov(y_k - \hat{y}_k) = E\{(y_k - \hat{y}_k - E\{y_k - \hat{y}_k\})(y_k - \hat{y}_k - E\{y_k - \hat{y}_k\})^T\}$$
(3.49)

Suponiendo que la esperanza del error es cero $E\{y_k - \hat{y}_k\} = 0$ se tiene que:

$$cov(y_k - \hat{y}_k) = E\{(e_k - \psi_k^T \hat{\theta}_k)(e_k - \psi_k^T \hat{\theta}_k)^T\}$$
(3.50)

Desarrollando se obtiene:

$$cov(y_k - \hat{y}_k) = E\{e_k e_k^T\} - E\{\psi_k^T \hat{\theta}_k e_k^T\} - E\{e_k \hat{\theta}_k^T \psi_k\} + E\{\psi_k^T \hat{\theta}_k \hat{\theta}_k^T \psi_k\}$$
(3.51)

Finalmente utilizando que $E\{e_k e_k^T\} = \sigma_k^2$ se obtiene que:

$$cov(y_k - \hat{y}_k) = \sigma_k^2 I + \sigma_k^2 \psi_k^{\ T} (\psi_k \psi_k^{\ T})^{-1} \psi_k$$
(3.52)

Así finalmente se tiene que:

$$\overline{f_k}(z_i) = \psi_{i,k}{}^T \hat{\theta}_k + \bar{\alpha} \sqrt{1 + \sigma_k^2 \psi_{i,k}{}^T (\psi_k \psi_k{}^T)^{-1} \psi_{i,k}}$$
(3.53)

$$\underline{f}_{k}(z_{i}) = \psi_{i,k}{}^{T}\widehat{\theta}_{k} - \underline{\alpha} \sqrt{1 + \sigma_{k}^{2}\psi_{i,k}{}^{T}(\psi_{k}\psi_{k}{}^{T})^{-1}\psi_{i,k}}$$
(3.54)

Con $i = 1 \dots N$. Y donde $\underline{\alpha}, \overline{\alpha}$ deben de ser sintonizados de acuerdo al porcentaje de datos que se quiera contener dentro del intervalo de confianza.

3.5.2 Intervalo de confianza utilizando optimización

En este método propuesto en (Škrjanc, 2005), a diferencia del anterior no se fija un porcentaje de datos para el cual se desea el mínimo intervalo de confianza, sino que se realiza una optimización para que se contenga la mayor cantidad de datos dentro del intervalo de confianza y al mismo tiempo optimizando que su ancho sea el menor.

La optimización a realizarse asume la forma de función difusa para los limites del intervalo, así realiza una optimización min-max sobre la distancia entre la función difusa del límite y la función difusa del modelo. Para esto, ajusta el valor de los parámetros de la función difusa del límite del intervalo, sujeto a distintas restricciones dependiendo de si se busca el límite superior o el inferior del intervalo de confianza. Así matemáticamente la optimización descrita resulta de la siguiente forma:

Para encontrar \underline{f} :

$$minmax \left| y(k) - \sum_{r=1}^{N_r} \beta_r(x(k)) \underline{\theta}_r^T x(k) \right|$$
(3.52)

s. a.:
$$y(k) - \sum_{r=1}^{N_r} \beta_r(x(k)) \underline{\theta}_r^T x(k) \ge 0$$
 (3.53)

Para encontrar \overline{f} :

$$minmax \left| y(k) - \sum_{r=1}^{N_r} \beta_r(x(k)) \overline{\theta}_r^T x(k) \right|$$
(3.54)

s.a.:
$$y(k) - \sum_{r=1}^{N_r} \beta_r(x(k)) \overline{\theta}_r^T x(k) \le 0$$
 (3.55)

Así encontrando $\overline{\theta}$ y $\underline{\theta}$ se obtienen las funciones difusas para los límites del intervalo de confianza ya que el β_r de las premisas y el x de las entradas del modelo son las mismas del modelo difuso TS ya identificado.

3.6 Resultados: Intervalo de confianza

Para que los intervalos de confianza contaran con la mayor generalidad posible en cuanto a los conjuntos de datos, se utilizó el modelo difuso TS ya identificado con los datos de entrenamiento, luego se realizaron los intervalos de confianza con los datos de prueba y finalmente los intervalos de confianza fueron evaluados utilizando el conjunto de datos de validación.

3.6.1 Resultados método de la covarianza difusa del error

Para este método es necesario primero sintonizar los $\overline{\alpha}$ y $\underline{\alpha}$ según el grado de confianza requerido. Para analizar los resultados se decidió utilizar una confianza del 95% y del 60%. Los resultados se muestras en la figura 34:



Figura 34: Resultados sintonización

a generar los intervalos de confianza obteniéndose los siguientes resultados:

Habiendo obtenido los $\overline{\alpha}$ y $\underline{\alpha}$ desde predicción a un paso hasta predicción a 96 pasos se procedió



Figura 35: Intervalo de confianza 95% a 1 paso



Intervalo de confianza 95% predicción a 15 pasos

Figura 36: Intervalo de confianza 95% a 15 pasos



Figura 37: Intervalo de confianza 95% a 96 pasos

Se puede apreciar en las figuras 35, 36 y 37 que en general la mayoría de los datos reales caen dentro del intervalo ya que al sintonizarse para una confianza del 95% los anchos de los intervalos son amplios. Además el intervalo es el mismo para cada predicción solo tiende a aumentar su ancho a medida que aumenta el número de pasos lo cual se desprende del método utilizado.

Para una confianza del 60% se obtuvieron los siguientes resultados:



Figura 38: Intervalo de confianza 60% a 1 paso







Figura 40: Intervalo de confianza 60% a 96 pasos

En este caso los intervalos son más estrechos al caso de 95%, sin embargo, la mayoría de los datos están contenidas en el intervalo lográndose siempre confianzas superiores al 60% esto se debe a que debido que el modelo TS tiene muy buenos resultados de predicción exigirle apenas un 60% de confianza resulta muy bajo.

La siguiente tabla muestra cual fue el grado de confianza obtenido para cada caso:

	Predicción a un paso	Predicción a 15 pasos	Predicción a 96 pasos
Sintonizado al 95%	100%	94.88%	95.63%
Sintonizado al 60%	100%	76.80%	77.89%

Tabla 12: Grado de confianza en las predicciones

3.6.2 Resultados método de optimización

En este método no se requiere obtener parámetros sintonizables para cada predicción, solo se requiere realizar una optimización para cada límite del intervalo de confianza encontrando la matriz de parámetros correspondiente, luego solo se varían las entrada del modelo TS de cada limite y se obtiene el intervalo de confianza, es decir, el intervalo de confianza encontrado con este método ya es dinámico en sí mismo. Los parámetros encontrados para cada intervalo corresponden a:

Para el intervalo inferior $\underline{\theta}$:

j	θ_0^{j}	$ heta_1^{j}$	$ heta_2^{j}$	θ_3^{j}	$ heta_4^{j}$
1	1.6316	0.1945	-0.3267	$3.019 \cdot 10^{-4}$	$-8.095 \cdot 10^{-5}$
2	-0.0522	0.4033	8.2926 10-4	0.002	$-1.5 \cdot 10^{-4}$

Tabla 13: Parámetros límite inferior del intervalo

Para el intervalo superior $\overline{\theta}$:

j	$ heta_0^{\ j}$	$ heta_1^{j}$	$ heta_2^{j}$	$ heta_3^{j}$	$ heta_4^{j}$
1	1.7482	0.2075	0.0227	$4,6849 \cdot 10^{-4}$	$-2.1011 \cdot 10^{-5}$
2	0.0782	0.2189	$-4.7491 \cdot 10^{-4}$	0.0036	$-6.2367 \cdot 10^{-4}$

Tabla 14: Parámetros límite superior del intervalo

Utilizando los valores obtenidos, se realizaron pruebas para las tres mismas predicciones del método de la covarianza, obteniéndose los siguientes resultados:



Figura 41: Intervalo de confianza a 1 paso



Figura 42: Intervalo de confianza a 15 pasos



Figura 43: Intervalo de confianza a 96 pasos

Es posible apreciar que la mayoría de los datos reales están contenidos dentro de los intervalos ya que al aumentar la variabilidad de los datos en las picos de potencia también aumenta el intervalo, y viceversa para los datos pequeños de potencia.

En la siguiente tabla se resumen los resultados del grado de confianza del intervalo para cada caso:

	Predicción a un paso	Predicción a 15 pasos	Predicción a 96 pasos
Grado de confianza	96.0057%	95.389%	95.9449%
Tabla 15: Cradas da confianza mátada da antimización			

Tabla 15: Grados de confianza método de optimización

Dadas las diferencias de ambos métodos no es sencilla la comparación de su desempeño, pero dadas las magnitudes alcanzadas por el método de la covarianza para el 95% de confianza en

contraste con el método de optimización, es notorio que es más eficiente el segundo, ya que logra confianzas superiores al 95% con intervalos más estrechos. En conclusión se obtienen mejores resultados el segundo método para confianzas altas, sin embargo, su desventaja está en que no otorga libertad para elegir el grado de confianza, por lo tanto si se desea una confianza baja sería más conveniente utilizar el método de la covarianza ya que el método de la optimización encontrará un intervalo con una confianza más ancho que el método de la covarianza sin necesidad de ello. Como para esta aplicación se requieren confianzas superiores al 95% es preferible el método de optimización ya que en este se logra la confianza deseada con intervalos de menor ancho que en el método de la covarianza.

Capítulo 4 : EMS basado en control predictivo robusto para microrred Huatacondo

En este capítulo se tiene como finalidad la inclusión de las herramientas de modelación estudiadas en los capítulos anteriores, al utilizar el modelo TS obtenido en el capítulo 3 en el EMS convencional ya existente en Huatacondo, para realizar las predicciones de potencia eólica de la microrred. Además se aplicará un control predictivo robusto basado en el intervalo de confianza difuso del método de optimización, el cual fue estudiado en el capítulo 3, para así considerar la incertidumbre de la predicción de potencia eólica dentro de la optimización realizada por el EMS para obtener el despacho de las unidades de la microrred.



Figura 44: Potencias reales EMS convencional

Las predicciones para la demanda fueron realizadas a partir de redes neuronales, mientras que las predicciones de potencia solar se realizaron a partir de modelos de radiación de cielo claro con nubosidad y finalmente las predicciones de potencia eólica fueran realizadas con el modelo difuso TS del capítulo 3.

Cabe destacar que la función de costoutilizada por el optimizador del EMS aún no considera una penalización para el uso de baterías, y tampoco considera un costo para el consumo de agua. Así la función de costo a minimizarse utilizada en este capítulo es la que se muestra a continuación:

$$J = \delta_t \sum_{t=1}^T C(t) + \sum_{t=1}^T C_s(t) + C_{US} \delta_t \sum_{t=1}^T P_{US}(t)$$
(4.1)

4.1 Enfoque robusto EMS

En esta sección se tiene como objetivo insertar la modelación de la incertidumbre de la potencia eólica dentro de la optimización con horizonte deslizante realizada por el EMS, mediante un control predictivo robusto basado en intervalos de confianza difusos.

En el capítulo 3 se obtuvo que el modelo de predicción para la potencia eólica con menores errores cuadráticos medios fue el modelo difuso TS mientras que el intervalo de confianza difuso más adecuado para la aplicación fue el intervalo de confianza difusa obtenido mediante optimización. Así el control predictivo robusto propuesto consta de un EMS que realiza dos optimizaciones en paralelo cada una alimentada de dos días de datos históricos y prediciendo hacia dos días en el futuro. El primer optimizador obtiene las predicciones de potencia eólica utilizando como modelo de predicción la función difusa que define el límite superior del intervalo de confianza obtenido en el capítulo 3, mientras que el segundo optimizador obtiene las predicción la función difusa que corresponde al límite inferior del intervalo de confianza. Así se obtendrán 2 despachos tanto para la unidad generadora diesel como para el banco de baterías, obteniéndose para cada caso un despacho único que se obtiene como se muestra a continuación.

En el caso del diesel:

$$P_{diesel-EMS\,enfoque\,robusto} = \frac{\overline{P}_{die} + \underline{P}_{die}}{2} \tag{4.2}$$

En el caso del banco de baterías:

$$P_{bat \ descarga-EMS \ enfoque \ robusto} = \frac{\overline{P}_{bat-des} + \underline{P}_{bat-des}}{2}$$
(4.3)

Donde \overline{P}_{die} corresponde al despacho del generador diesel y $\overline{P}_{bat-des}$ corresponden a la consigna de descarga para el banco de baterías, ambos obtenidos a partir de la optimización que modela las predicciones de potencia eólica utilizando el límite superior del intervalo de confianza. Mientras que \underline{P}_{die} y $\underline{P}_{bat-des}$ corresponden a las consignas para el generador diesel y para la descarga del banco de baterías, pero utilizando el límite inferior del intervalo de confianza como modelo de predicción de la potencia eólica.

Para realizar las simulaciones del enfoque robusto EMS se utilizaran 5 réplicas, de cuatro días de largo cada una, cuyos datos corresponden a los que aún no han sido utilizados en los procesos de identificación de modelos y obtención de sus respectivos intervalos de confianza. Así para probar

el EMS con el enfoque robusto se utilizaron los 20 días finales de la base de datos disponible. A continuación en la figura 45 se exponen las cinco réplicas utilizadas:



Figura 45: Réplicas de potencia eólica

Se puede apreciar que cada replica consta de cuatro días, esto debido a que el optimizador requiere de hasta 2 días pasados para predecir dos días futuros y luego a medida que avanzan el tiempo se va alimentando de más datos reales cada cuatro horas, de manera de ir mejorando la calidad de predicción a medida que avanza el tiempo. Así el optimizador primero predice para dos días en el futuro con la información de dos días pasados y genera un despacho a partir de la optimización, luego pasan 4 horas y predice nuevamente pero esta vez utilizando los datos reales de las 4 horas que han pasado, de manera de mejorar la predicción y así en adelante cada 4 horas.

4.2 Resultados

En esta sección se resumen los resultados obtenidos para las simulaciones del EMS Huatacondo tanto para el caso del EMS convencional como para el enfoque robusto de EMS. Los resultados se muestran en tablas que resumen los costos para cada situación y en figuras que muestran gráficamente la operación de las unidades de la microrred en cada caso y otras variables relevantes para el análisis.

4.2.1 EMS convencional

En las tablas se muestran los costos obtenidos para cada réplica, utilizando el EMS convencional para el caso en que la potencia eólica es modelada utilizando predicciones del modelo TS y AR, se escogió comparar con el modelo AR debido a que este fue el que entregó mayores errores cuadráticos medios en las predicciones por lo que la diferencia de costos será más notoria.

Costo [Posos]		Predicción eólica		% Do Ahorro
	Costo [Pesos]	Modelo AR	Modelo TS	% De Anorro
	Arranque de generador Diesel (real)	4000	4000	0
ca]	Operación de generador Diesel (real)	38505.9519	33070.1137	14.1169
épli	No combustible (real)	0	0	0
R	Costo total real	42505.9519	37070.1137	12.7884
0	Arranque de generador Diesel (real)	4000	3000	25
ica	Operación de generador Diesel (real)	37325.7741	36872.9275	1.2132
épli	No combustible (real)	0	0	0
R	Costo total real	41325.7741	39872.9275	3.5156
	Arranque de generador Diesel (real)	4000	3000	25
ica 3	Operación de generador Diesel (real)	36469.7838	36780.9951	-0.8533
tépl	No combustible (real)	0	0	0
L.	Costo total real	40469.7838	39780.9951	1.702
ca 4	Arranque de generador Diesel (real)	3000	3000	0
	Operación de generador Diesel (real)	34477.3718	32731.5504	5.0637
tépli	No combustible (real)	0	0	0
R	Costo total real	37477.3718	35731.5504	4.6583
	Arranque de generador Diesel (real)	4000	4000	0
Réplica 5	Operación de generador Diesel (real)	33331.3874	37468.4813	-12.412
	No combustible (real)	0	0	0
	Costo total real	37331.3874	41468.4813	-11.082
nedio licas	Arranque de generador Diesel (real)	3800	3400	10.5263
	Operación de generador Diesel (real)	36022.0538	35384.8136	1.769
² ron Rép	No combustible (real)	0	0	0
ш	Costo total real	39822.0538	38784.8136	2.6047

Tabla 16: Costos EMS convencional

Se puede extraer de los resultados obtenidos en las tablas, que efectivamente la predicción de potencia eólica basada en TS obtiene en promedio costos menores para las réplicas en comparación a la basada en modelo AR. Esto tiene sentido ya que es un modelo con menores errores de predicción por lo que, por lo general, se acerca más a la generación real de potencia eólica, lo que se traduce en que el diésel efectivamente trabaje minimizando su costo, mientras que al tener un mayor error de predicción el modelo AR el optimizador hace operar al generador minimizando su costo, pero suponiendo cantidades erradas de potencia eólica lo que lo lleva a alejarse del óptimo real de operación deseado. Si el modelo de predicción subestima la potencia eólica que habrá, el optimizador del EMS hará que el generador diésel trate de suplir esta falta de potencia eólica, siendo que podría haberse usado en menor medida si se hubiera conocido con mayor exactitud la potencia eólica real que se generaría. Por otro lado si la potencia eólica predicha por el modelo es sobrestimada, el optimizador del EMS haría al generador diésel

trabajar menos de lo que debería lo que llevaría por ejemplo a no cargar suficientemente el banco de baterías de la microrred y en los siguientes instantes de tiempo tendría que trabajar de más para suplir este error, por lo que finalmente el diésel también gastaría más de lo que debería. En resumen mientras más alejada sea la predicción de potencia eólica de la potencia eólica real que se genere, ya sea por encima o por debajo de esta predicción, el optimizador del EMS no podrá encontrar un óptimo adecuado a la generación real de aerogenerador, lo que se traducirá en costos mayores ya que el objetivo del optimizador es minimizar el costo total del sistema y se estará entorpeciendo su trabajo con predicciones muy alejadas de la realidad.

En las figura 46 y 47 que se presentan a continuación se puede apreciar el accionar de cada unidad de la microrred para la réplica 1, utilizando el optimizador del EMS con las predicciones eólicas AR y TS. Para las demás réplicas el comportamiento es bastante similar por lo que basta con exponer los resultados de la réplica 1 para apreciar tendencias.



Figura 46: Operación microrred EMS convencional utilizando modelo AR (Réplica 1)



Figura 47: Operación microrred EMS convencional utilizando modelo TS (Réplica 1)

En las figuras 46 y 47 se puede apreciar que utilizando el modelo de predicción AR siempre el generador diésel incurre en mayores gastos que utilizando el modelo de predicción TS, por incurrir en mayores lapsos de tiempo de operación. Como se explicó al analizar los costos en las

tablas esto se debe a que la optimización arrastra un mayor error en el caso del modelo AR y por ende su funcionamiento no minimiza los costos adecuadamente, es decir, genera despachos que errados alejados del verdadero mínimo con lo que se obtienen mayores costos.

Como en el enfoque robusto se ha incluido el factor de la incertidumbre de la generación eólica es de interés incluir los resultados de reserva tanto para el generador diésel como para el banco de baterías, para el EMS convencional, con el fin de hacer comparaciones con los resultados del EMS con enfoque robusto.

Para el caso del diésel se sabe que su máxima capacidad es de 120 [kW] por lo tanto su reserva queda dada por su máxima capacidad menos su operación, siempre y cuando el generador diésel se encuentre encendido, ya que al estar apagado por su lento arranque no puede entregar reserva al sistema en un tiempo corto. La siguiente expresión resume como se obtiene la reserva del generador diesel en el EMS convencional:

$$R_{die-EMS\ convencional} = \begin{cases} 120[kW] - P_{diesel} & si\ el\ generador\ esta\ encendido & (4.4) \\ 0 & si\ el\ generador\ esta\ apagado \end{cases}$$

Así las reservas obtenidas para cada réplica utilizando el EMS convencional se muestran a continuación en la figura 48:



Figura 48: Reserva generador diesel de situación actual

De las figuras se puede apreciar que siempre que el generador diésel esta encendido se cuenta con cantidades de reserva altísimas del orden del 67% al 83% de su capacidad nominal, esto se debe al sobredimensionamiento del generador diesel para la demanda del sistema donde es utilizado. Se tiene una demanda total que no supera los 40 [kW] y el generador diesel puede entregar hasta 120 [kW] tres veces mayor que la demanda, que además es satisfecha mediante generación eólica, solar y mediante descarga del banco de baterías.

En el caso del banco de baterías la reserva también puede ser obtenida como la capacidad máxima de la batería menos la potencia que esté entregando al sistema, sin embargo, su capacidad máxima varía según su estado de carga (SOC), pero este SOC está limitado por la optimización del EMS el cual no permite que el SOC baje del 13%. La potencia máxima del banco de baterías de la microrred de Huatacondo es de 40 [kW], en este caso el banco tiene una respuesta rápida, por ende su reserva está dado por su potencia máxima menos su operación de descarga para todo instante limitándose a la restricción de energía impuesta por el EMS. Así la reserva del banco de baterías queda dada por la siguiente expresión:

$$R_{Bat-EMS\ convencional} = \begin{cases} 40\ [kW] - P_{descarga} & si \ SOC > 13\% \\ 0 & si \ SOC \le 13\% \end{cases}$$
(4.5)

La reserva que puede entregar el banco de baterías para cada réplica estudiada se muestra en la figura 49:



Figura 49: Reserva Banco de baterías de situación actual

Se puede apreciar que el Banco de baterías cuenta con un muy buen respaldo de reserva pudiendo cubrir prácticamente toda la demanda del sistema por algunos instantes, esto se debe a que el banco también es relativamente grande en comparación a los niveles de demanda del sistema, pudiendo entregar hasta 40 [kW] cifra muy similar a los niveles máximos de demanda que se pueden observar en el sistema.

4.2.2 Resultados EMS enfoque robusto

A continuación se pueden observar en las tablas los resultados obtenidos en cuanto a costos, para el enfoque robusto en cada uno de los dos límites del intervalo de confianza, contrastadas además

con los resultados utilizando la predicción de potencia eólica con la cual se originó el intervalo de confianza.

Costo [Pesos]		Potencia eólica predicha según:			
		Límite inferior intervalo de confianza	Predicción de potencia eólica	Límite superior intervalo de confianza	
	Arranque de generador Diesel (real)	4000	4000	3000	
ica1	Operación de generador Diesel (real)	36739.2964	33070.1137	34676.4449	
Képl	No combustible (real)	0	0	0	
Ч	Costo total real	40739.2964	37070.1137	37676.4449	
0	Arranque de generador Diesel (real)	4000	3000	3000	
ica 2	Operación de generador Diesel (real)	35898.3908	36872.9275	34570.5559	
épli	No combustible (real)	0	0	0	
R	Costo total real	39898.3908	39872.9275	37570.5559	
~	Arranque de generador Diesel (real)	4000	3000	3000	
ica	Operación de generador Diesel (real)	37577.1511	36780.9951	39292.2124	
tépli	No combustible (real)	0	0	0	
R	Costo total real	41577.1511	39780.9951	42292.2124	
Réplica 4	Arranque de generador Diesel (real)	4000	3000	2000	
	Operación de generador Diesel (real)	35814.5902	32731.5504	32665.0751	
	No combustible (real)	0	0	0	
	Costo total real	39814.5902	35731.5504	34665.0751	
	Arranque de generador Diesel (real)	4000	4000	4000	
ica (Operación de generador Diesel (real)	37756.9233	37468.4813	38572.5242	
tépl	No combustible (real)	0	0	0	
R	Costo total real	41756.9233	41468.4813	42572.5242	
0	Arranque de generador Diesel (real)	4000	3400	3400	
icas	Operación de generador Diesel (real)	36757.2704	35384.8136	35355.3625	
'rom Vépl	No combustible (real)	0	0	0	
Ч	Costo total real	40757.2704	38784.8136	38755.3625	

Tabla 17: Resultados EMS enfoque robusto

Para aclarar el significado de los resultados de costos también se obtuvieron errores medios de predicción de potencia eólica para cada caso, para lograr esto se obtuvieron errores medios para cada réplica en cada ventana de tiempo de predicción y se promediaron para obtener un error medio de predicción para cada réplica en los 3 casos estudiados. El error medio fue calculado como la diferencia entre la predicción y los datos reales, así un error medio positivo refleja una tendencia de sobrestimación de la potencia, mientras que un error negativo corresponde a una subestimación de la potencia.

	Error medio [kW]				
	Límite inferior intervalo de confianza	Predicción de potencia eólica	Límite superior intervalo de confianza		
Réplica1	-0.6119	-0.0348	0.2827		
Réplica 2	-0.6997	-0.2108	0.0543		
Réplica 3	-0.5720	0.4571	0.8421		
Réplica 4	-1.2802	-0.6118	0.2880		
Réplica 5	-0.4399	0.1749	0.9642		

Tabla 18: Error medio de predicción

En el caso de la réplica 1 el menor de los costos se obtuvo utilizando el modelo TS para predecir la potencia eólica, seguido de la utilización del límite superior del intervalo de confianza para predecir la potencia eólica y finalmente el más costoso resultó ser el límite inferior del intervalo, lo mismo sucede para la réplica 3. Este comportamiento refleja que la predicción del modelo TS está subestimando la potencia eólica como se aprecia en su error medio, es por esto que el límite superior se presenta como una mejor solución que el inferior, ya que el error de predicción es mayor para el inferior, sin embargo no lo subestima a un grado tan alto de hacer que el límite superior se presente como una mejor solución que la predicción misma del modelo TS.

En la réplica 5 ocurre que la predicción TS está sobrestimando la potencia eólica generada como refleja su error medio, es por esto que el límite inferior se presenta como mejor solución que el límite superior del intervalo, sin embargo al igual que en el caso anterior no lo sobrestima lo suficiente como para que el límite inferior del intervalo se presente como una mejor solución que la predicción misma.

En las réplicas 2 y 4 ocurre que el menor costo se encuentra utilizando como predictor el límite superior del intervalo de confianza lo que quiere decir que la predicción TS está subestimando la potencia eólica en un grado importante tal como se puede apreciar en la tabla de errores medios, acercándose más el límite superior al comportamiento real de la potencia eólica y en consecuencia, siendo la peor solución el límite inferior.

En las figuras 50 y 51 que se muestran a continuación se puede observar el funcionamiento de las unidades de la microrred para los casos de los límites superior e inferior del intervalo de confianza, para cada la réplica 1, es suficiente con estudiar la réplica 1 para entender las tendencias ya que las demás réplicas tienen comportamientos similares y sus diferencias se reflejan en los costos.



Figura 50: Operación microrred EMS enfoque robusto límite inferior (Réplica 1)



Figura 51: Operación microrred EMS enfoque robusto límite superior (Réplica 1)

De las figuras es posible apreciar una clara diferencia de comportamientos al utilizar el límite superior del intervalo de confianza como modelo de predicción y al utilizar el límite inferior del intervalo con el mismo fin. Cuando se utiliza el límite superior se está sobreestimando la potencia eólica que habrá como se pudo apreciar en la tabla 18, por lo que el optimizador podría tender a hacer que el diesel se encienda menos de lo necesario, pero como la optimización se realiza con horizonte deslizante, ésta es actualizada en cuanto a datos reales cada 4 horas por lo que al encender el diesel menos tiempo de lo que debió haberse hecho para las optimizaciones futuras tenderá a tener que encender más veces el diesel o un mayor tiempo debido al déficit producido por la poca operación del diesel en periodos pasados. En el caso del límite inferior se está subestimando la potencia eólica por lo que el optimizador tiende a encender más de lo necesario el diesel con lo que se incurre en mayores costos.

Utilizando las ecuaciones 4.2 y 4.3 se obtiene el despacho único de las unidades de generación diesel y de la descarga del banco de baterías a partir del enfoque robusto para el EMS. Los resultados obtenidos para las 5 réplicas se muestran en las figuras 52 y 53 donde además son contrastados con los resultados del EMS convencional.









El despacho obtenido para el generador diesel con el EMS con enfoque robusto tienes en general un número mayor de arranques que el despacho obtenido con el EMS convencional, teniendo un segundo arranque extraen las réplicas 2, 3 y 4 ya que refleja dos escenarios extremos producto del intervalo de confianza, mientras que en el caso del banco de baterías la descarga es muy similar al caso del enfoque convencional ya que al no ser considerada en la función de costos del optimizador su uso no varía mucho cambiando los escenarios de generación eólica.

Además de la operación con el enfoque robusto es importante obtener la reserva para cada caso ya que la reserva es un factor a comparar con el EMS convencional que refleja parte de la seguridad del sistema. Tanto para el caso del generador diésel como para el banco de baterías

para obtener la reserva, se utiliza el mismo mecanismo que para el caso del EMS convencional pero esta vez utilizando los despachos obtenido a partir del enfoque robusto.

$$R_{die-EMS enfoque robusto}$$

$$= \begin{cases} 120[kW] - P_{diesel-EMS enfoque robusto} & si \ el \ generador \ esta \ encendido \\ si \ el \ generador \ esta \ apagado \end{cases}$$

$$R_{Bat-EMS \ enfoque \ robusto} = \begin{cases} 40 \ [kW] - P_{descarga} & si \ SOC > 13\% \\ 0 & si \ SOC \le 13\% \end{cases}$$

$$(4.6)$$

$$(4.6)$$

Utilizando este enfoque robusto se obtiene un costo de operación distinto a los obtenidos para cada réplica en el enfoque convencional como se puede apreciar en la siguiente tabla en donde son contrastados con los resultados del EMS convencional.

Costo [Pesos]		EMS enfoque robusto	EMS convencional
	Arranque de generador Diesel	4000	4000
éplica 1	Operación de generador Diesel	35707.8707	33070.1137
	No combustible	0	0
R	Total	39707.8707	37070.1137
0	Arranque de generador Diesel	4000	3000
ica 2	Operación de generador Diesel	36508.0097	36872.9275
tépli	No combustible	0	0
ц	Total	40508.0097	39872.9275
~	Arranque de generador Diesel	4000	3000
ica	Operación de generador Diesel	36606.4963	36780.9951
Répli	No combustible	0	0
	Total	40606.4963	39780.9951
1	Arranque de generador Diesel	4000	3000
ica (Operación de generador Diesel	35337.2523	32731.5504
(épl	No combustible	0	0
Ъ	Total	39337.2523	35731.5504
2	Arranque de generador Diesel	4000	4000
ica	Operación de generador Diesel	38433.3365	37468.4813
tépl	No combustible	0	0
Ч	Total	42433.3365	41468.4813
ledio icas	Arranque de generador Diesel	4000	3400
	Operación de generador Diesel	36518.5931	35384.8136
ron Répl	No combustible	0	0
P	Total	40518.5931	38784.8136

Tabla 19: Costos enfoque robusto

Para complementar el análisis comparativo del EMS convencional y el EMS con enfoque robusto en las figuras 54 y 55 se comparan los resultados obtenidos para las reservas del
generador diesel y del banco de baterías respectivamente. El comportamiento de la reserva es idéntico en las partes del gráfico donde pareciese desaparecer la línea punteada.



Comparación de reservas del generador diesel (EMS convencional y EMS robusto)

Figura 54: Comparación de reservas del generador diesel



Figura 55: Comparación de reservas del banco de baterías

En el caso del banco de baterías las diferencias entre las reservas para cada enfoque del EMS son mínimas debido a que su uso no está considerado en la función de costo que optimiza el EMS, por esto aunque en el enfoque robusto se considera la incertidumbre de predicción a través del intervalo de confianza este no tiene impacto sobre el uso de la batería y por ende tampoco en su reserva. Algo distinto ocurre con el generador diesel cuyo despacho cambia considerablemente dependiendo del enfoque que se utilice en el caso del EMS convencional de la tabla 19 se puede apreciar en el promedio de las réplicas que se obtiene un costo menor que en el caso del EMS con enfoque robusto, pero en la figura 54 se puede apreciar con claridad que la reserva es mayor contando con reserva en lapsos de tiempo donde el generador diesel para el EMS convencional tiene reserva cero.

Debido a la poca diferencia del comportamiento del banco de baterías en ambos enfoques la inclusión de la incertidumbre a través del enfoque robusto solo se ve reflejada en la operación del generador diesel. El enfoque robusto se le da una representación al intervalo de escenarios posibles de predicción a través del intervalo de confianza con lo que se genera un despacho a mayor costo que si se utiliza simplemente la predicción a través de un modelo único de potencia eólica, pero a cambio de esto se obtiene un despacho con niveles de confiabilidad mayores para el sistema reflejados en su reserva. En el caso del EMS convencional se tiene un EMS que genera despachos a bajo costo pero de baja confiabilidad, mientras que en el EMS robusto propuesto se obtiene un despacho de mayor confiabilidad pero a un costo más alto. A pesar que la diferencia de costos puede llevar a pensar que es conveniente utilizar el EMS convencional por sobre el EMS con enfoque robusto, se debe tener en cuenta que al contar con un sistema menos confiable el sistema corre riesgos mayores de fallar ya que cuenta con un menor respaldo por parte del generador diesel en caso de emergencia, y si el sistema falla esto se puede traducir en costos aún mayores debido a energías no suministradas y equipos dañados.

Este enfoque podría mejorarse aún más para lograr un control EMS que garantice un despacho adecuado de la microrred con costos menores. Para lograr esto es necesario integrar dentro de la optimización misma realizada por el EMS las incertidumbres de predicción de manera de que la minimización de costos tome en cuenta la incertidumbre. En el enfoque propuesto se minimiza sin considera incertidumbre y esta es agregada luego por medio de reservas, lo ideal sería que la minimización tomara en cuenta esta incertidumbre para obtener un despacho óptimo confiable cuyas reservas asociadas ya implícitamente consideren la incertidumbre de predicción.

Capítulo 5 : Conclusiones

Este trabajo presentó el desarrollo, evaluación y comparación de modelos lineales AR, ARX y del modelo difuso TS aplicados a la predicción de generación de potencia eólica. Luego de estudiados los modelos de predicción, se evaluaron dos técnicas para modelar la incertidumbre del mejor modelo predictivo, a través de intervalos de confianza: una a partir de la varianza de la modelación y otro a partir de una optimización. Finalmente se propone una manera de incorporar tanto el nuevo modelo de predicción, como la modelación de su incertidumbre dentro del EMS para generar un enfoque robusto de éste.

Para concluir cual modelo es más apropiado para la predicción de potencia eólica, se identificó cada uno a partir de datos históricos, y luego de evaluar en predicciones a un paso, a 15 pasos y a 96 pasos, el modelo TS obtuvo un mejor desempeño para todos los horizontes de predicción estudiados. Particularmente, el error cuadrático medio es del orden de: 0.9184 [kW] para el modelo AR, 0.7952 [kW] para el modelo ARX y 0.6022 [kW] en el modelo TS, para la predicción a 96 pasos.

Habiéndose determinado que el modelo de predicción más adecuado dentro de los estudiados es el modelo TS, se analizaron las dos técnicas para generar intervalos de confianza difusos a partir del modelo TS. La primera de ellas generando un intervalo de confianza a partir de un factor asociado a la covarianza de la predicción del modelo. A este factor se le suma al modelo TS para obtener el límite superior del intervalo y se le resta para obtener el límite inferior, a su vez, el factor es multiplicado por un valor escalar que debe ser sintonizado. El segundo método corresponde a una minimización del ancho del intervalo de confianza que logre el máximo de confianza. Se realizaron pruebas en predicciones a 1 paso, a 15 pasos y a 96 pasos, obteniéndose una confianza del 95,63% para el primer método y del 95,9449% para el segundo. A pesar de que en cuanto a resultados la confianza es similar, el segundo método lo logra con intervalos de anchos considerablemente menores durante el periodo de operación, por lo cual se decidió utilizar este último para modelar la incertidumbre.

Finalmente se incorporaron el nuevo modelo de predicción TS y el intervalo de confianza en el EMS existente, primero se analizó la influencia de una mejor modelación de predicción de potencia eólica dentro del optimizador del EMS, para esto se utilizaron cinco réplicas de tiempo y se contrastaron las minimizaciones obtenidos para el modelo TS y el modelo AR. Se obtuvo para todas las réplicas que la utilización de un mejor modelo de predicción, en este caso el modelo TS, implica una optimización con condiciones más cercanas a la realidad, por ende una minimización que genera un despacho de menor costo para el sistema.

Para incorporar los intervalos de confianza en el EMS, se planteó un enfoque en el que dos optimizadores operan en paralelo, cada uno utilizando el límite superior y el límite inferior intervalo de confianza respectivamente, como modelo de predicción de potencia eólica. Luego teniendo los dos despachos para cada uno de los optimizadores se obtiene una operación y una para el generador diesel y para la descarga del banco de baterías, reflejando así la incertidumbre a partir de los límites del intervalo de confianza. En contraste con los resultados para el EMS actual fue posible observar que los costos asociados al enfoque robusto para el EMS resultaron más altos que en el caso del EMS convencional, esto se debe a el EMS robusto incurre en mayores costos con la finalidad de garantizar un despacho más confiable para el sistema. Al contrastar las reservas del EMS actual y las determinadas por el EMS convencional se pudo analizar que en el EMS robusto se obtienen reservas para el generador diesel en más instantes de tiempo que en el caso del EMS convencional, brindándole más seguridad al sistema aunque a un costo mayor.

Por último cabe destacar que el enfoque robusto propuesto, realiza dos optimizaciones para luego incorporar la incertidumbre a partir de ellas por lo tanto se tienen resultados que le brindan confiabilidad al sistema, pero no a un mínimo costo. Lo ideal sería implementar una optimización que incorpore la incertidumbre de manera de realizar una minimización de costos que como restricción este considerando la incertidumbre de predicción.

5.1 Trabajo futuro

- Estudiar otras opciones de modelos de predicción y otras técnicas matemáticas para modelar la incertidumbre.
- Realizar una optimización robusta, que incorpore la incertidumbre de predicción dentro de sus condiciones de optimización.
- Aplicar las técnicas estudiadas a las demás unidades de la microrred (consumo, generación solar) de manera de obtener un EMS robusto para la totalidad del sistema.
- Implementar en una microrred real el EMS robusto.

Referencias

[1] Fernando Lanas. "Desarrollo y validación de un modelo de optimización energética para una microrred", 2011.

Günter D. Roth Meteorología. Formaciones nubosas y otros fenómenos meteorológicos.
[2] Situaciones meteorológicas generales. Pronósticos del tiempo. Barcelona:Ediciones Omega, 2003 (edición original alemana: Munich, 2002)

- [3] R.Palma-Behnke, C.Benavides, F.Lanas, B.Severino, L.Reyes, J.Llanos, D.Sáez. "A Microgrid Energy Management System Based on the Rolling Horizon Strategy", 2013.
- [4] R. Lasseter, "Microgrids" in *Proc. IEEE Power Engineering Society, Winter Meeting* 2002,vol. 1, 2002, pp. 305-308 vol.1
- [5] B. Lasseter, "Microgrids [distributed power generation]," in *Proc. IEEEPES Winter Meeting*, vol. 1, Jan./Feb. 2001, pp. 146-149.
- [6] Daniel E. Olivares, Claudio A. Cañizares, Mehrdad Kazerani "A Centralized Optimal Energy Management System for Microgrids", *IEEE*. 2011
- [7] N. Hatziargyriou, G. Contaxis, M. Matos, J. A. P. Lopes, G. Kariniotakis, D. Mayer, J. Halliday, G. Dutton, P. Dokopoulos, A. Bakirtzis, J. Stefanakis, A. Gigantidou, P. O'Donnell, D. McCoy, M. J. Fernandes, J. M. S. Cotrim, and A. P. Figueira, "Energy management and control of island power systems with increased penetration from renewable sources," in *IEEE-PES Winter Meeting*, vol. 1, Jan. 2002, pp. 335-339.
- [8] M. Korpas and A. T. Holen, "Operation planning of hydrogen storage connected to wind power operating in a power market," *IEEE Transactions on Energy Conversion*, vol. 21, no. 3, Sept. 2006, pp. 742-749
- [9] E. Alvarez, A. C. Lopez, J. Gómez-Aleixandre, and N. de Abajo, "Online minimization of running costs, greenhouse gas emissions and the impact of distributed generation using microgrids on the electrical system," in *Proc. IEEE PES/IAS Conference on Sustainable Alternative Energy (SAE)*, Sept. 2009, pp. 1-10.
- [10] S. Chakraborty and M. G. Simoes, "PV-microgrid operational cost minimization by neural forecasting and heuristic optimization," in *Proc. IEEE Industry Applications Society Annual Meeting IAS '08*, Oct. 2008, pp. 1-8.

- [11] C. M. Colson, M. H. Nehrir, and S. A. Pourmousavi, "Towards real-time microgrid power management using computational intelligence methods," in *Proc. IEEE-PES General Meeting*, Jul. 2010, pp. 1-8.
- [12] M. D. Ilic, and S. X. Liu, *Hierarchical Power System Control: Its Value in a Changing Industry (Advances in Industrial Control).* London: Springer, 1996.
- [13] C. Hernandez-Aramburo, T. Green and N. Mugniot, "Fuel consumption minimization of a microgrid," *IEEE Trans. Ind. Appl.*, vol. 41, no. 3, pp. 673-681, May-June 2005.
- [14] F. Pilo, G. Pisano, and G. Soma, "Neural implementation of microgrid central controllers," in *Proc. IEEE 5th International Conference on Industrial Informatics*, 2007, vol. 2, June 2007, pp. 1177-1182.
- [15] S. Conti, R. Nicolosi, and S. Rizzo, "Optimal dispatching of distributed generators in an mv autonomous micro-grid to minimize operating costs of emissions," in *Proc. IEEE International Symposium on Industrial Electronics (ISIE)*, 2010, July 2010, pp. 2542-2547.
- [16] C. Colson, M. Nehrir, and C. Wang, "Ant colony optimization for microgrid multiobjective power managemen,t" in *Proc.*, *IEEE Power Systems Conference and Expositions*, 2009. (*PSCE '09*), March 2009, pp. 1-7
- [17] H. Kanchev, D. Lu, B. Francois, and V. Lazarov, "Smart monitoring of a microgrid including gas turbines and a dispatched pv-based active generator for energy management and emissions reduction," in *Proc. IEEE Innovative Smart Grid Technologies Confernece Europe (ISGT Europe)*, 2010, OCT. 2010, pp. 1-8.
- [18] C. Shwaegerl, L. Tao, P, Mancarella, and G. Strbac, "A multi-objective optimization approach for assessment of technical, commercial and environmental performance of microgrids," *European Transactions on Electrical Power*, vol. 21, no., pp. 1269-1288, 2011.
- [19] M. R. Zadech, A. Haijimiragha, M. Krok, S. Allan, and A. Palizban, "Bella coola microgrid generation optimization with a hydro-electric unit operating in isochronous mode," in *Proc. CIGRE 2011*, Sept. 2011.
- [20] F. Katirae, R. Iravani, N. Hatziargyriou, and A. Dimeas, "Microgrids management: Controls and operation aspects of microgrids," *IEEE Power Eenergy Mag.*, vol. 6, no. 3, pp. 54-65, May/Jun. 2008

- [21] F. C. Scheweppe and J. Wildes, "Power system static-state estimation, Part I: Exact model," *IEEE Trans. Power App. Syst.*, vol. PAS-89, no. 1, pp. 120-125, Jan. 1970.
- [22] T. Logenthiram, D. Srinivasan, and D. Wong, "Multi-agent coordination for der in microgrid" in *Proc. IEEE International Conference on Sustainable Energy Technologies*, 2008 (ICSET '08), Nov. 2008, pp. 77-82.
- [23] W. D. Zheng and J. D. Cai, "A multi-agent system for distributed energy resources control in microgrid," in *Proc. IEEE 5th International Conference on Critical Infrastructure* (CRIS), 2010, Sept. 2010, pp. 1-5.
- [24] D. Sáez and A. Cipriano, "A new method for structure identification of fuzzy models and its applications to a combined cycle power plant" in *Engineering Intelligent Systems*, 2001.
- [25] Škrjanc, I.; Blazic, S.; Agamennoni, O.; "Interval Fuzzy Model Identification Using -Norm," Fuzzy Systems, IEEE Transactions on , vol.13, no.5, pp.561-568, Oct. 2005
- [26] Škrjanc I., "Fuzzy confidence interval for pH titration curve", Applied Mathematical Modelling, Volume 35, Issue 8, August 2011, Pages 4083-4090, ISSN 0307-904X, 10.1016/j.apm.2011.02.033.