



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

**IDENTIFICACIÓN DE SISTEMAS BASADA EN INTELIGENCIA
COMPUTACIONAL Y SU APLICACIÓN A LA MODELACIÓN DE UN
AEROGENERADOR**

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

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELECTRICISTA

GABRIEL FELIPE MORENO CALDERÓN

SANTIAGO DE CHILE
ABRIL 2011



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

**IDENTIFICACIÓN DE SISTEMAS BASADA EN INTELIGENCIA
COMPUTACIONAL Y SU APLICACIÓN A LA MODELACIÓN DE UN
AEROGENERADOR**

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

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELECTRICISTA

GABRIEL FELIPE MORENO CALDERÓN

PROFESOR GUÍA:
SRA. DORIS SÁEZ H.

PROFESOR CO-GUÍA:
SR. MARCOS ORCHARD C.

MIEMBRO DE LA COMISIÓN:
SR. GONZALO ACUÑA L.

SANTIAGO DE CHILE
ABRIL 2011

A mis papás Felipe y Elbita.
A mis hermanos Daniel y Catalina.
A los que vendrán en el futuro.

RESUMEN DE LA TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN
CIENCIAS DE LA ING. MENCIÓN ELÉCTRICA, Y DE LA MEMORIA PARA
OPTAR AL GRADO DE INGENIERO CIVIL ELECTRICISTA
POR: GABRIEL MORENO CALDERÓN
FECHA: 27/04/2011
PROFESOR GUÍA: SRA. DORIS SÁEZ HUEICHAPAN
PROFESOR CO-GUIA: SR. MARCOS ORCHARD CONCHA

Identificación de Sistemas basada en Inteligencia Computacional y su Aplicación a la Modelación de un Aerogenerador

Es muy común recurrir a modelación de sistemas en ingeniería de control. En sistemas de control avanzado, éstos incluso pueden formar parte del controlador; por ejemplo para realizar predicciones acerca del comportamiento futuro del sistema y así lograr generar acciones de control óptimas en el presente.

Cuando los procesos a modelar son muy complejos, usualmente se recurre a técnicas de identificación de sistemas para la obtención de modelos. Existen diversos métodos de identificación, algunos más adecuados que otros para representar sistemas no-lineales. Entre esas técnicas se encuentra la identificación de sistemas difusos.

En este trabajo se propone un nuevo método de identificación difusa basado en Algoritmos Genéticos y Optimización por Enjambre de Partículas, técnicas que tienen su origen en aplicaciones del ámbito de inteligencia computacional. Ambos métodos requieren del ajuste de una serie de parámetros para su funcionamiento, por lo que se realizó un análisis de sensibilidad de los parámetros de ajuste del nuevo método.

En particular, el presente trabajo plantea la utilización de un simulador desarrollado a medida de un aerogenerador como proceso a identificar. Se asumió que el simulador es el sistema real sobre el cual se está trabajando. La modelación del proceso está basada en sistemas de ecuaciones diferenciales y algebraicas. El aerogenerador es no-lineal, en tiempo continuo con variables continuas. Dado que los aerogeneradores son alimentados con la energía proveniente del viento, cuya velocidad es un proceso estocástico, el aerogenerador es un sistema estocástico.

Se realizaron simulaciones de tiempo continuo y se tomaron datos de manera discreta, para, posteriormente, obtener un modelo de caja negra del sistema mediante diferentes técnicas de identificación. Se contrastaron los modelos obtenidos mediante el nuevo método con otros modelos difusos obtenidos mediante otras técnicas existentes y con modelos lineales autorregresivos de variable exógena. El criterio de comparación utilizado fue el error cuadrático medio de las predicciones a 1, 10 y N pasos obtenidas con cada uno de los modelos.

Los modelos obtenidos con el nuevo método mostraron un buen desempeño en las predicciones a 1 y 10 pasos. No así en las predicciones a N pasos, ámbito en el cual se deberían concentrar los esfuerzos en desarrollos futuros.

Agradecimientos

Los años en la Universidad sin duda alguna marcaron mi vida y todo lo que vendrá en el futuro. Durante mi carrera hubo personas que me acompañaron en todo momento y que me dieron todo su apoyo. Agradezco sinceramente a ellas, ya que si no hubieran sido partícipes de todo esto, este proceso no hubiera sido lo mismo.

A mi Profesora Guía, Dra. Doris Sáez, por conducir mi trabajo y por haberme acogido en su grupo de investigación. También por haberme escogido como su Ayudante y Profesor Auxiliar durante innumerables semestres. Siempre estuvo disponible para solucionar mis inquietudes y tuve su apoyo incondicional, incluso más allá de lo académico. Siempre se preocupó de mi bienestar cuando lo necesité. Estaré eternamente agradecido por todos sus consejos.

A mi Profesor Co-Guía, Dr. Marcos Orchard, por sus fundamentales aportes al desarrollo de mi trabajo, por su excelente disposición, buen humor y por darme su apoyo permanente cuando todo se veía cuesta arriba. Al Profesor Miembro de la Comisión, Dr. Gonzalo Acuña, por sus valiosos comentarios sobre mi Tesis.

A mi gran amigo Daniel Kraus, con quien enfrentamos juntos toda la etapa de Plan Común. Siempre recordaré las maratónicas sesiones de estudio en donde casi siempre una buena conversación y la buena mesa primaban por sobre el conocimiento. Agradezco mucho a su familia, los Kraus Friedmann, quienes siempre me han dado su apoyo y me han acompañado en los momentos importantes de mi vida.

A mi gran amigo Rodrigo Asenjo, quien fue el artífice de mi incorporación a el Departamento de Ingeniería Eléctrica y cuyo apoyo fue fundamental para sobrevivir los años de especialidad. Siempre estaré impresionado de lo que logramos durante la carrera, sobre todo al recordar todas las presentaciones y trabajos que hicimos juntos, cuyo nivel de realización y magistralidad cautivaba

a grandes y chicos, e incluso a nosotros mismos.

A mis queridos amigos Rodrigo Wolf, Matías Goldsmith, Yair Ventura, Daniel Felzensztein, Alan Meyer, Alejandro Kisiliuk, Felipe Soto Meza, Diego Muñoz, Ignacio Erbetta, Sebastián Etchegaray y Pablo Huijse. Muchas gracias por todos los buenos momentos. Todos ustedes me seguirán acompañando durante toda mi vida.

A mis compañeros de laboratorio Jacqueline Llanos, Carolina Ponce, Alfredo Núñez, Francisco Valencia y Freddy Milla. A la Sra. Eliana Monardes, por su simpatía y apoyo.

A mis alumnos. De ustedes aprendí más que de nadie.

Finalmente, desde lo más profundo de mi alma, agradezco a mi papás Felipe y Elbita. Todo lo que soy y todo lo que he logrado ha sido gracias a ustedes. Su ejemplo, dedicación y forma de vivir la vida me llena de orgullo y es la motivación para cada día hacer todo lo posible para ser una persona buena y para lograr grandes cosas. También quiero agradecer a mis queridísimos hermanos Daniel y Catalina, quienes me han acompañado todos los días desde la infancia, en las buenas y en las malas. Gracias por todo el apoyo fundamental y la paciencia que me han tenido.

Agradezco al Proyecto Fondecyt N^o 1110047 por el apoyo económico.

Muchas gracias a todos. Espero haber aportado algo valioso en sus vidas, así como ustedes han aportado mucho a la mía.

Gabriel Moreno Calderón.

Santiago, Abril de 2011.

Índice general

1. Introducción	7
1.1. Sistemas	10
1.1.1. Modelación de sistemas	14
1.1.2. Identificación de sistemas	16
1.2. Objetivos y metodología de trabajo.	31
1.3. Aerogenerador	32
1.3.1. Motivación	32
1.3.2. Descripción de un aerogenerador	36
2. Modelación de un aerogenerador	43
2.1. Bloque aerodinámico	43
2.2. Bloque mecánico	46
2.3. Bloque eléctrico	48
2.4. Diagrama de bloques integrado	59
3. Implementación de un simulador para un aerogenerador de 2 [MW]	60
3.1. Bloque viento	61
3.2. Bloque aerodinámico	62
3.3. Bloque mecánico	66
3.4. Bloque eléctrico	67
3.4.1. Máquina de inducción	68
3.4.2. Variador de frecuencia	69
3.5. Implementación de estrategias de control	71

3.5.1.	Control de velocidad de giro de la turbina	73
3.5.2.	Control del variador de frecuencia	73
3.6.	Discusión	75
4.	Método de identificación de modelos difusos	77
4.1.	Algoritmos genéticos	78
4.1.1.	Terminología básica	79
4.1.2.	Codificación	80
4.1.3.	Mutación	80
4.1.4.	Crossover	81
4.1.5.	Operadores de selección	81
4.1.6.	Descripción general de los algoritmos genéticos	82
4.2.	Optimización por enjambre de partículas	83
4.2.1.	Modelo canónico de optimización por enjambre de partículas	83
4.2.2.	Algoritmo PSO	84
4.3.	Nuevo algoritmo de identificación difusa	85
4.3.1.	Elección de la estructura del modelo	87
4.3.2.	Identificación de los parámetros de las premisas	87
4.3.3.	Identificación de los parámetros de las consecuencias con PSO	92
4.4.	Número de iteraciones algoritmo	96
4.4.1.	Búsqueda exhaustiva	96
4.4.2.	Búsqueda por GA	97
4.5.	Discusión	97
5.	Aplicación del algoritmo de identificación para la obtención de un modelo del aerogenerador	98
5.1.	Set de datos para la identificación del sistema	98
5.2.	Análisis de sensibilidad del nuevo algoritmo	103
5.2.1.	GA: Número de individuos	105
5.2.2.	GA: Número de iteraciones	106
5.2.3.	GA: Probabilidad de crossover	107

5.2.4.	GA: Probabilidad de mutación	109
5.2.5.	PSO: Número de partículas	110
5.2.6.	PSO: Número de iteraciones	111
5.2.7.	Parámetros seleccionados	112
5.3.	Modelo ARX	113
5.3.1.	Modelo obtenido por búsqueda exhaustiva	113
5.3.2.	Modelo obtenido por análisis de sensibilidad	115
5.4.	Modelo Babuska	120
5.4.1.	Modelo obtenido por búsqueda exhaustiva	120
5.4.2.	Modelo obtenido por análisis de sensibilidad	122
5.5.	Modelo obtenido a partir de nuevo algoritmo (cálculo de parámetros de las consecuencias mediante mínimos cuadrados)	125
5.5.1.	Modelo obtenido por base de regresores fija	126
5.6.	Modelo obtenido a partir de nuevo algoritmo (cálculo de parámetros de las consecuencias mediante PSO)	128
5.6.1.	Modelos obtenidos por base de regresores fija	129
5.6.2.	Modelos obtenidos por análisis de sensibilidad	136
5.7.	Resultados	138
5.7.1.	Tiempos computacionales	138
5.7.2.	Resultados de modelos obtenidos por búsqueda exhaustiva	139
5.7.3.	Resultados de modelos obtenidos por análisis de sensibilidad	144
6.	Conclusiones	148
A.	Estructura de los modelos obtenidos	153
A.1.	Modelo Babuska	153
A.1.1.	Modelo obtenido por búsqueda exhaustiva	153
A.1.2.	Modelo obtenido por análisis de sensibilidad	157
A.2.	Modelo obtenido a partir de nuevo algoritmo (cálculo de parámetros de las consecuencias mediante mínimos cuadrados)	164
A.2.1.	Modelo obtenido por base de regresores fija	164

A.3. Modelo obtenido a partir de nuevo algoritmo (cálculo de parámetros de las consecuencias mediante PSO)	170
A.3.1. Modelos obtenidos por base de regresores fija	170
A.3.2. Modelos obtenidos por análisis de sensibilidad	181

Capítulo 1

Introducción

El método de razonamiento utilizado por el hombre fue continuamente perfeccionándose, hasta llegar a lo que se conoce hoy en día como el método científico. Dicho método consiste en varias etapas cuyo fin es la obtención de una teoría que explique ciertos aspectos de algún fenómeno de interés en forma general.

En todo este proceso es clave la capacidad de inferencia del científico. El proceso mental que involucra la inferencia requiere primero de la abstracción del sistema. El científico forma una imagen mental del proceso que está observando, conservando en esa imagen todos aquellos atributos que son relevantes para el planteamiento de las inferencias y descartando los que considere irrelevantes.

Es usual que los científicos se apoyen en modelos para mejorar el entendimiento de los objetos o fenómenos observados. Por ejemplo, si se quiere estudiar la conectividad de las calles de una ciudad, éstas se pueden representar por grafos, lo que puede ayudar a la comprensión del sistema.

Básicamente, un modelo es una representación simplificada y acotada de una parte de la realidad, en donde se incluyen sólo los aspectos relevantes necesarios y útiles para la solución de un problema en particular. Se pueden modelar desde objetos reales, tanto animados como inanimados, hasta situaciones físicas bastante complejas. Cada modelo es creado con un propósito particular y, muy probablemente, su utilidad será bastante acotada a su propósito original [5].

Es muy importante prescindir de aquellos aspectos que no se consideren fundamentales para la resolución del problema, porque dichas simplificaciones son las que permiten un nivel de abstracción de la realidad suficiente como para facilitar la comprensión de ciertos aspectos del fenómeno en

estudio [5].

Una vez que se dispone del modelo, es posible apoyarse en él para realizar inferencias deductivas para averiguar la lógica que gobierna el comportamiento del modelo y, eventualmente, intentar extrapolar dichas conclusiones al sistema real.

En ingeniería se busca generar modelos de sistemas, de tal forma de estudiar su comportamiento bajo distintas condiciones, sin intervenir sobre el sistema real o para conocer cómo se comportará un sistema en el futuro, incluso antes de ser construido. La utilización de modelos resulta muy útil y práctica, porque hacer intervenciones directamente sobre sistemas en funcionamiento puede resultar muy costoso e incluso peligroso [29].

En la Figura 1.0.1 se muestra un esquema que resume la utilización de modelos como apoyo al método científico [16].

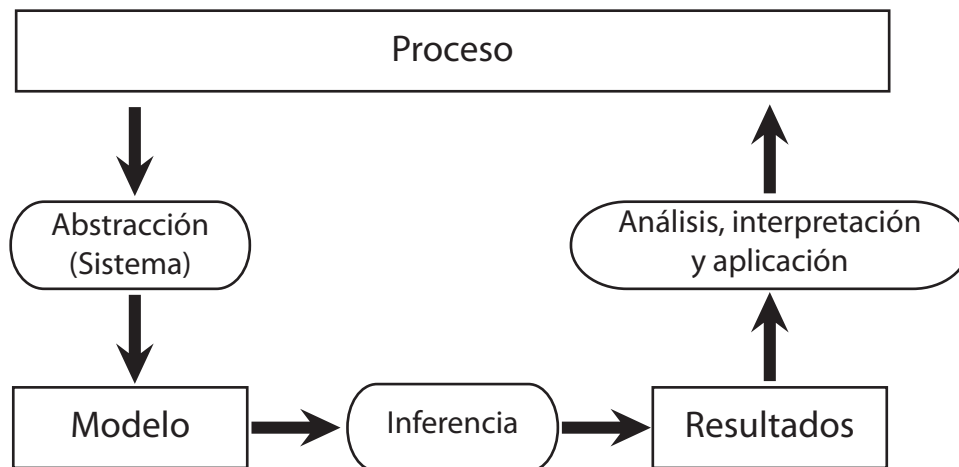


Figura 1.0.1: Esquema de utilización de modelos para apoyar el método científico.

Los modelos, en general, pueden clasificarse en modelos *icónicos*, *análogos* y *simbólicos* [23]. Los modelos icónicos consisten en una réplica de las propiedades exactas de un sistema real, pero a menor escala. Por ejemplo los modelos a escala de aeronaves y los mapas entran en esta categoría. Los modelos análogos se basan en el hecho que dos sistemas distintos pueden tener patrones de comportamiento similares cuando se cumplen ciertas condiciones. Por ejemplo se puede utilizar un modelo hidráulico para representar un circuito eléctrico, porque al hacer una equivalencia correcta entre las variables y parámetros relevantes de cada sistema, se observa que éstos responden de una forma similar. Los modelos simbólicos representan sistemas reales mediante símbolos, como

ecuaciones matemáticas o programas computacionales [6, 23].

Particularmente, modelar matemáticamente un sistema consiste en encontrar un conjunto de ecuaciones diferenciales o algebraicas que representen el comportamiento del sistema real. Dicho sistema puede llegar a ser muy complejo y distintos tipos de ecuaciones pueden representar al mismo sistema real con distinto nivel de detalle o rango de validez [6].

Como ya se mencionó, una vez que se dispone de un modelo y sus parámetros han sido calibrados, el objetivo es utilizarlo para visualizar como se comportaría el sistema que representa, en distintas condiciones. En algunos casos es posible resolver el sistema de ecuaciones, encontrando una solución analítica que representará el comportamiento del modelo. Otras veces el sistema es de tal complejidad que la solución analítica no es evidente. En estos casos se recurre a diferentes métodos numéricos para evaluar el modelo para distintos valores de variables y parámetros. Así es posible observar como evolucionaría el sistema modelado a medida que transcurre un cierto intervalo de tiempo.

Lo anterior corresponde a lo que se conoce por *simulación*. Simulación corresponde a la imitación de la operación de un proceso o sistema a medida que transcurre el tiempo [5]. La simulación involucra la generación de una historia artificial del sistema basada en un modelo. La visualización de dicha historia permitirá realizar inferencias y obtener conclusiones acerca de los fenómenos de interés en el sistema real. Es muy común recurrir a computadores para realizar simulaciones, porque la cantidad de evaluaciones que se necesita realizar al modelo matemático harían muy lento el proceso si se hiciera de manera manual [5].

La simulación es una herramienta para el análisis de sistemas, y presenta una serie de ventajas [6]:

- Se pueden estudiar procesos más rápido, en forma más económica y exhaustiva que utilizando una planta real o un prototipo.
- Las variables de operación se pueden llevar al extremo de sus rangos de operación, lo que normalmente no es posible en la planta real por razones de seguridad.
- Es posible realizar modificaciones al modelo fácilmente, lo que permite la evaluación de distintas políticas de operación o de diseño y observar si es razonable y compatible realizar cambios.
- Se puede realizar análisis de sensibilidad con respecto a los parámetros del sistema. Esto es

especialmente útil para el diseño de estrategias de control adecuadas.

- Permite el desarrollo de estrategias de optimización de la operación del sistema bajo múltiples criterios.
- Es posible realizar estudios de la estabilidad del sistema y sus componentes ante perturbaciones y variaciones en las condiciones de operación.

1.1. Sistemas

En el contexto de modelación y simulación de sistemas, es necesario especificar qué se entiende por sistema. A continuación se especificará lo anterior y se explicarán definiciones importantes deben tenerse en cuenta.

Un sistema es una abstracción de un grupo de objetos vinculados entre sí a través de cierta interacción regular o interdependencia orientada hacia el cumplimiento de algún propósito [23]. Por ejemplo, en una faena minera de cobre toda la maquinaria y personal que intervienen en la línea productiva están relacionados de tal forma que, a lo largo de varias etapas, es posible obtener un cátodo de cobre de alta pureza a partir de simples rocas.

Es común que los sistemas se vean afectados por cambios que ocurren fuera de él. A todo aquello que queda fuera del sistema, se conoce como entorno del sistema. Dependiendo de los propósitos y objetivos que se tengan para un problema en particular, parte de las decisiones que se deben tomar al definir un sistema es la elección de sus límites. Dichos límites determinarán cuando se acaba el sistema y donde comienza el entorno.

Además de los límites, es necesario precisar otras características del sistema para lograr representarlo. Existen algunas definiciones importantes que ayudan a realizar esta tarea. De acuerdo a [5], una *entidad* es un objeto de interés en el sistema. Un *atributo* es una propiedad de una entidad. Una *actividad* representa un periodo de tiempo de una duración específica, mientras que un *evento* corresponde a un fenómeno instantáneo que puede cambiar el estado del sistema. Las actividades y eventos serán *endógenos* cuando éstos ocurran al interior del sistema y serán *exógenos* cuando estos ocurran en el entorno y afecten al sistema.

Una *variable* corresponde a un elemento, característica o factor que es susceptible a variar o cambiar.

En primera instancia, las variables pueden dividirse en variables *internas* y *externas*. Variables del primer tipo son aquellas que son variables de *entrada*, *salida* y *perturbaciones*. Básicamente representan los elementos del sistema que tienen contacto con el entorno del sistema. Variables del segundo tipo corresponden a las variables de *estado*, *parámetros* y *perturbaciones* originadas al interior mismo del sistema.

Las entradas son variables que pueden ser modificadas en forma externa al sistema mediante eventos exógenos generados por un experimentador. Las perturbaciones son variables cuyo origen también es externo al sistema, afectando a éste, pero que no ofrecen la posibilidad de ser manipuladas por un experimentador. Su origen radica en condiciones ambientales incontrolables. Las perturbaciones pueden ser medibles o no medibles. En caso de ser medibles, pueden incorporarse a la modelación del sistema. Tanto las variables de entrada como las perturbaciones son las responsables de la evolución del sistema.

Las salidas son variables que cambian como consecuencia de la interacción de las variables de entrada y perturbaciones con el sistema. Pueden ser observadas por un experimentador, sin embargo éste no puede alterar su valor directamente, a menos que intervenga sobre las entradas.

Los parámetros son valores asociados a atributos que son intrínsecos al sistema.

Las variables de estado describen la evolución del sistema y relacionan de forma unívoca un segmento de variables de entrada con otro de salida, de acuerdo a la dinámica del sistema.

En algunos sistemas se pueden encontrar perturbaciones internas que también afectarán sobre las variables de estado.

Los sistemas pueden clasificarse de acuerdo a varios criterios. Un tipo de clasificación es con respecto a su origen: un sistema puede ser *natural* o *artificial*, dependiendo si se encuentra en la naturaleza en forma independiente a la acción del ser humano o si este fue creado por intervención del hombre.

Desde el punto de vista de la naturaleza de los procesos internos que gobiernan el sistema, estos pueden ser clasificados como [5, 6]:

- **Sistemas determinísticos:** Son aquellos en que las variables de salida están determinadas para todo instante de tiempo y están determinadas en forma única. Sólo dependen de la evolución de las variables de entrada y de las condiciones iniciales del sistema.
- **Sistemas estocásticos:** La evolución de estos sistemas está determinada por variables que

tienen asociadas cierta densidad de probabilidad. En ellos no es posible determinar los valores de las variables de salida a partir de las entradas y condiciones iniciales. Hay un factor de incertidumbre asociado a las variables.

De acuerdo a la cantidad de entradas de un sistema, éstos pueden ser:

- Sistemas monovariantes: Poseen sólo una entrada y una salida.
- Sistemas multivariantes: Poseen más de una entrada y/o más de una salida.

De acuerdo a la continuidad de las variables que forman el sistema, éstos se pueden clasificar en:

- Sistemas de variable continua: En este tipo de sistemas, las variables pueden tomar todos los valores reales contenidos en el rango de acción factible de la variable.
- Sistemas de variable discreta: En este tipo de sistemas, las variables sólo pueden tomar algunos valores contenidos en el rango de acción factible de la variable.

Según las características de continuidad del tiempo, los sistemas pueden ser:

- Sistemas de tiempo continuo: Las variables están definidas en todos los instantes.
- Sistemas de tiempo discreto: Las variables están definidas sólo en algunos instantes o subintervalos.

Según el comportamiento de sus características a medida que transcurre el tiempo:

- Sistemas invariantes en el tiempo: Son aquellos cuyos parámetros no cambian en el tiempo.
- Sistemas variantes en el tiempo: Son aquellos cuyos parámetros cambian con el tiempo.

Según la linealidad de sus variables:

- Sistemas lineales: Son aquellos sistemas que al ser excitados por una combinación lineal de entradas, generan como salida la combinación lineal de las salidas independientes asociadas a cada una de las componentes que forman la entrada.
- Sistemas no-lineales: Son aquellos que no son lineales.

Según la memoria de las variables de un sistema:

- Sistemas sin memoria: Son aquellos en que la respuesta del sistema depende sólo de la entrada aplicada en el instante actual.
- Sistemas con memoria: Son aquellos en que la respuesta del sistema depende tanto de la entrada aplicada en el instante actual, como de toda la historia previa del sistema.

Al momento de diseñar un sistema de control o de realizar un diseño de procesos desde el punto de vista de investigación operativa, el procedimiento que usualmente se realiza es el siguiente [23]:

- Formulación del problema.
- Modelación del sistema.
- Validación del modelo.
- Uso del modelo para probar distintas soluciones.
- Implementación de la solución.

Este procedimiento es iterativo, porque es usual volver a pasos previos a medida que se va avanzando con el trabajo y van surgiendo nuevas inquietudes o se repara en detalles que no habían sido tomados en cuenta inicialmente. Por ejemplo, cuando se está trabajando en la validación del modelo, es muy común volver a replantear supuestos y simplificaciones realizadas en los primeros dos pasos del procedimiento.

En la parte de modelación de sistemas, el esquema de trabajo usual es el siguiente:

- Modelación del sistema.
- Identificación de los parámetros del sistema.
- Simulación del sistema.

Este procedimiento también es iterativo, por las mismas razones que lo es el procedimiento anterior. Cada uno de los puntos mencionados anteriormente es muy sensible al tipo de sistema que se desea modelar y analizar. Hay muchas formas de abordar cada parte del trabajo, sin embargo no todos los métodos y técnicas existentes son adecuados para todos los sistemas. Hay que prestar mucha atención al momento de elegir la técnica más adecuada para abordar cada problema en particular. En este trabajo se pondrá énfasis en la parte relacionada con modelación de sistemas.

A continuación se muestra una reseña acerca de distintas metodologías existentes en cada uno de los puntos mencionados.

1.1.1. Modelación de sistemas

La modelación de un sistema no es un proceso simple y es delicado. Requiere de un gran conocimiento del sistema o proceso que se está estudiando. La abstracción de las distintas magnitudes relevantes del sistema, y la correspondiente relación entre ellas, es un problema que debe ser abordado de distinta forma, dependiendo de la naturaleza del sistema.

Por lo general los sistemas y procesos consisten en la interconexión de varias etapas o unidades que juntas actúan como un todo. En la modelación es conveniente identificar las distintas partes que forman el sistema para crear un modelo basado en bloques independientes entre sí, pero que al unirlos formen una representación adecuada del sistema.

Anteriormente se mencionó que un modelo es una representación simplificada de la realidad. Un paso importante en la modelación es establecer cuáles serán las hipótesis que se considerarán para realizar la simplificación. Estas deben ser coherentes con los objetivos que se persiguen y estar sujetas a las características del sistema y del modelo, por lo que deben ser debidamente justificadas para obtener modelos que se adecuen a lo que se busca. La complejidad del modelo involucra un compromiso entre la fidelidad de la descripción del proceso y compatibilidad con las herramientas computacionales y matemáticas disponibles. Normalmente un modelo muy complejo describirá el sistema más fielmente que uno menos completo, sin embargo el esfuerzo computacional o de resolución analítica que involucra trabajar con el primero será mayor que con el segundo. Se debe tener precaución de construir un modelo adecuado para las herramientas disponibles, pero que sea lo suficientemente complejo para que no escape de los objetivos generales del problema.

Hay una correlación importante entre la construcción de un modelo y de los datos de entrada medidos en los que éste se basa [5]. Como punto de inicio en la modelación de un sistema, por lo general se utilizan datos reales medidos a través de diversos medios. Es necesario verificar la calidad de dichos datos en forma previa a la modelación. Si los datos son erróneos, o presentan alto porcentaje de error, dichas imprecisiones quedarán incorporadas al modelo, lo que incluso puede invalidarlo.

Existen dos esquemas para la obtención de un modelo: empírico y analítico. También se puede

aplicar una metodología híbrida que incluya ambos esquemas.

El esquema empírico consiste en excitar el proceso con entradas conocidas, para luego medir las salidas y otras variables accesibles. El objetivo es correlacionar las entradas con sus respuestas. Este tipo de métodos se suelen llamar de caja negra y, por lo general, son utilizados cuando no hay un conocimiento acabado acerca de la dinámica del sistema [13].

Las entradas típicas para estos esquemas son impulsos, pulsos, trenes de pulsos, ondas sinusoidales, escalones, rampas y ruido blanco. Los tipos de entradas y sus parámetros deben ser acordes a la dinámica del sistema a modelar, teniendo en cuenta características como la linealidad del sistema, tiempo característico de respuesta del sistema y el tipo de modelo que se desea obtener.

Esta técnica requiere del uso de herramientas matemáticas como estadística, transformaciones de Laplace y Fourier, entre otras. En la Sección 1.1.2 *Identificación de sistemas* se explican con mayor detalle algunas de estas técnicas.

Por otra parte, los métodos analíticos requieren un conocimiento detallado del sistema que se quiere modelar. Consisten en una serie de relaciones matemáticas entre las variables externas e internas del sistema.

En el contexto de la modelación analítica, se pueden construir modelos usando métodos basados en leyes de conservación o métodos basados en el principio de mínima acción [6].

Los métodos basados en leyes de conservación se sustentan en el hecho que en ciertos procesos ciertas propiedades de éste se conservan a medida que evoluciona; por ejemplo la energía, la masa, la cantidad de movimiento o la carga eléctrica. Las magnitudes que se conservan dan origen a las ecuaciones de balance en un cierto instante y lugar del espacio.

Suponiendo que la magnitud que se conserva se denomina X , las ecuaciones de balance se basan en el concepto que en cierto instante y posición, la acumulación de X en el sistema corresponderá a la diferencia entre la entrada neta de X al sistema y la generación neta de X en el sistema.

Es conveniente precisar que la entrada neta de X al sistema corresponde a la diferencia entre la cantidad de X que entra al sistema y la cantidad de X que sale de éste. Por otra parte, la generación neta de X se define como la diferencia entre la generación de X y la destrucción de X , ambas al interior del sistema.

Para el planteamiento de las ecuaciones se definen los siguientes términos:

$F(t)$: Flujo neto de entrada de X al sistema.

$G(t)$: Velocidad de generación de X en el sistema.

Δt : Intervalo en el que se considera acumulación.

La acumulación de X en el sistema, en cierto instante, queda determinada por $X(t + \Delta t) - X(t)$. Considerando que la entrada neta de X al sistema es $F(t) \Delta t$ y que la generación neta de X es $G(t) \Delta t$, la ecuación de balance queda definida por:

$$X(t + \Delta t) - X(t) = F(t) \Delta t + G(t) \Delta t \quad (1.1.1)$$

Dividiendo todo por Δt y haciéndolo tender a cero, se obtiene la siguiente ecuación diferencial:

$$\frac{dX}{dt} = F(t) + G(t) \quad (1.1.2)$$

Cuando las propiedades globales del sistema en estudio no presentan variaciones espaciales, F y G son funciones que sólo dependen del tiempo y no de la posición. En ese caso se dice que el sistema es de parámetros concentrados y el modelo corresponde a una serie de ecuaciones diferenciales de primer orden.

En otros sistemas, llamados de parámetros distribuidos, sus propiedades globales sí dependen de la posición. En ese caso se debe hacer un balance en cada elemento de volumen dv y, por lo tanto, aparecen dependencias de F y G con respecto a la posición. Así se obtiene un modelo matemático en derivadas parciales con una dependencia tanto espacial como temporal.

1.1.2. Identificación de sistemas

La identificación de sistemas busca encontrar un modelo matemático que represente a un sistema en forma óptima, según algún criterio y para determinados fines. Los objetivos son básicamente los mismos que en la modelación fenomenológica analítica, sin embargo, esta disciplina busca ajustar las propiedades del modelo a las del sistema sin tener conocimiento específico sobre su fenomenología. Esto se conoce como modelos de caja negra [13].

Cuando existe cierto conocimiento parcial acerca de la dinámica del sistema a modelar, se utiliza ese conocimiento para determinar la estructura del modelo a utilizar, además de un procedimiento de ajuste para que el modelo cumpla con los objetivos propuestos. El procedimiento de ajuste puede corresponder a la estimación de los parámetros del modelo, mientras que el conocimiento sobre la

fenomenología del sistema se puede usar para seleccionar las variables relevantes para el modelo, por ejemplo. Estos modelos reciben el nombre de *modelos grises*.

Si el proceso que se desea modelar es ergódico, entonces mediante estimadores insesgados adecuados es posible obtener el valor esperado de los parámetros del un modelo utilizando datos de entrada y salida de una realización del experimento.

Para obtener un conjunto de datos adecuado para la identificación del modelo es necesario excitar el sistema con una función de entrada adecuada. Las señales de entrada U deben ser *persistentemente excitantes* para lograr una buena identificación. En general, se deben excitar todos los modos de operación de la planta para que aparezcan incluidos en la modelación [13].

En el caso ideal, se utiliza ruido blanco como entrada. De esa forma se asegura que no existe correlación entre la función de entrada y la salida obtenida desde la planta y se elimina la posibilidad de incorporar sesgo en la estimación de los parámetros.

Existen diversas técnicas de identificación. Algunas de ellas son muy adecuadas para representar sistemas lineales o sistemas no-lineales en torno a un punto de operación. En el caso de sistemas no-lineales se realiza una linealización del sistema en estudio en torno a un punto de operación de éste. El modelo obtenido sólo será válido en torno al punto de operación entorno al cual se calibró el modelo. Ejemplos de metodologías de identificación lineal de sistemas son los modelos autorregresivos con variables exógenas (*Auto Regressive model with eXternal inputs*, ARX) y modelos autorregresivos de media móvil con variables exógenas (*Auto Regressive Moving Average with eXternal inputs*, ARMAX).

La mayoría de los sistemas tienen un comportamiento no lineal, excepto en un determinado rango de operación en donde pueden ser considerados lineales. Como se dijo anteriormente, se pueden utilizar modelos lineales para aproximar al sistema no lineal en torno a un punto de operación. El problema es que el desempeño del modelo lineal, por ejemplo sus características predictivas, se verá deteriorado al variar el punto de operación del sistema no lineal. Para describir globalmente el comportamiento del sistema se debe recurrir a modelos de caja negra adecuados para representar sistemas no-lineales. Existen varios tipos de modelos de caja negra adecuados, entre los que se encuentran los modelos difusos y las redes neuronales. La gran variedad y diferencias existentes entre los distintos tipos de modelos adecuados para este tipo de identificación hace que no sea posible obtener métodos generales de identificación, sino sólo para determinadas clases de modelos

de este tipo.

En este trabajo se trabajará con identificación de modelos ARX y de modelos difusos, por lo que a continuación se hará una introducción a ambos tipos de modelos y los métodos de identificación respectivos que se utilizan comúnmente.

1.1.2.1. Modelos autorregresivos con variables exógenas (ARX) e identificación de modelos ARX

Los modelos ARX son muy utilizados en la práctica para modelar sistemas de los cuales no se tiene una descripción fenomenológica adecuada. Este tipo de modelos está basado en ecuaciones de diferencia.

Se modelará el sistema dinámico mediante una ecuación de diferencia con perturbación de ruido blanco, como se indica en la ecuación X.

$$A(z^{-1}) \cdot y(k) = B(z^{-1}) \cdot u(k) + w(k) \quad (1.1.3)$$

En donde A y B son polinomios en el operador de retardo z^{-1} .

$$\begin{aligned} A(z^{-1}) &= 1 + a_1 \cdot z^{-1} + a_2 \cdot z^{-2} + \dots + a_{n_y} \cdot z^{-n_a} \\ B(z^{-1}) &= 1 + b_1 \cdot z^{-1} + b_2 \cdot z^{-2} + \dots + b_{n_u} \cdot z^{-n_a} \end{aligned}$$

$y(k)$ corresponde a las salidas medidas del sistema a modelar, mientras que $u(k)$ corresponde a sus entradas.

La salida de un modelo ARX puede escribirse según (1.1.4).

$$y(k) = \varphi_k^T \cdot \theta + w(k) \quad (1.1.4)$$

En donde

$$\begin{aligned} \varphi_k^T &= \left[-y(k-1) \quad -y(k-2) \quad \dots \quad -y(k-n_y) \quad u(k-1) \quad u(k-2) \quad \dots \quad u(k-n_u) \quad 1 \right] \\ \theta &= \left[a_1 \quad a_2 \quad \dots \quad a_{n_y} \quad b_1 \quad b_2 \quad \dots \quad b_{n_u} \quad c_{dc} \right]^T \end{aligned}$$

El vector de regresores φ_k^T sólo depende de señales medidas desde $k - 1$ hacia el pasado.

Cuando se quiere realizar identificación de modelos ARX, se deben encontrar valores del vector θ permita que el modelo represente en forma óptima a la planta de acuerdo a algún criterio, por ejemplo que error cuadrático medio entre la señal de salida y del sistema y la salida \hat{y} del modelo sea mínimo.

Para encontrar los valores de θ óptimos, se definen las siguientes matrices:

$$Y = \begin{bmatrix} y(n_y) & y(n_y + 1) & y(n_y + 2) & \cdots & Y(N) \end{bmatrix}^T$$

$$\Phi = \begin{bmatrix} -y(n_y - 1) & -y(n_y - 2) & \cdots & -y(1) & u(n_u - 1) & u(n_u - 2) & \cdots & u(1) & 1 \\ -y(n_y) & -y(n_y - 1) & \cdots & -y(2) & u(n_u) & u(n_u - 1) & \cdots & u(2) & 1 \\ -y(n_y + 1) & -y(n_y) & \cdots & -y(3) & u(n_u + 1) & u(n_u) & \cdots & u(3) & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ -y(N - 1) & -y(N - 2) & \cdots & y(N - n_y) & u(N - 1) & u(N - 2) & \cdots & u(N - n_u) & 1 \end{bmatrix}$$

De acuerdo a (1.1.4), Y y Φ se relacionan según (1.1.5).

$$Y = \Phi^T \cdot \theta \quad (1.1.5)$$

En (1.1.5), θ es una incógnita. Interesa encontrar valores de θ que minimicen el error cuadrático medio de (1.1.5). Para eso se realiza el siguiente procedimiento:

$$Y = \Phi \cdot \theta \quad / \Phi^T$$

$$\Phi^T \cdot Y = \Phi^T \cdot \Phi \cdot \theta$$

$$\theta = (\Phi^T \Phi)^{-1} \Phi^T \cdot Y$$

De esta forma se obtienen valores de θ óptimos para formar el modelo ARX.

1.1.2.2. Sistemas difusos e identificación de modelos difusos

Típicamente las decisiones a las que se ven enfrentados los computadores en un programa tienen respuestas basadas en la lógica Booleana. Si cierta condición, a la que el programa somete a prueba, es cierta, entonces se ejecuta una sentencia de instrucciones en particular, mientras que si es falsa, se ejecuta otra sentencia diferente. En este esquema de trabajo se basa la instrucción *IF-ELSE*, implementada en la mayoría de los lenguajes computacionales modernos. En la Figura 1.1.1 se muestra el funcionamiento de las sentencias condicionales en un programa computacional.

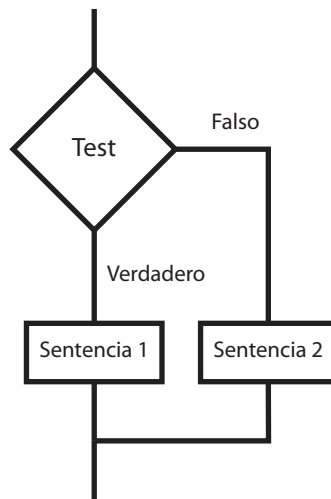


Figura 1.1.1: Sentencia If-Else.

A diferencia de los computadores, los seres humanos no razonan de forma tan precisa. La mayor parte del razonamiento humano se realiza clasificando y relacionando las situaciones a las que se enfrenta la persona en categorías que son relativas, que no tienen límites matemáticos claros y que muchas veces son cualitativas más que cuantitativas, por ejemplo:

1. El perro es más grande que el gato.
2. Hoy hace más calor que ayer.

Las personas son capaces de tomar decisiones basadas en información que es imprecisa y muchas veces ni siquiera es numérica. A pesar que los computadores son sólo capaces de procesar información numérica, los conjuntos difusos proveen una herramienta para representar información de manera imprecisa y cualitativa. A través de los conjuntos difusos es posible acercar el razonamiento computacional al que realizan las personas.

La teoría de conjuntos difusos fue enunciada por primera vez por Lotfi Zadeh [30]. Ésta se basa en que, en muchos casos, las clases en que se catalogan los objetos o conceptos presentes en el universo no tienen criterios de membresía precisamente definidos. Postuló los conjuntos difusos como clases de objetos con grados de pertenencia difusos.

Matemáticamente, un conjunto es una colección de objetos. Puede ser definido enumerando a sus miembros, o describiendo las características distintivas que cumplen todos sus elementos. En un conjunto tradicional, un elemento pertenece a un conjunto dado o bien no pertenece. En cambio, un conjunto difuso permite valores intermedios de pertenencia.

Los conjuntos difusos permiten formalizar expresiones lingüísticas que típicamente contienen algún grado de ambigüedad. Proveen un método para expresar matemáticamente conceptos relativos y abstractos, tales como "alto", "frío" o "rápido", que por esencia no son precisos. En conjuntos difusos, la ambigüedad existente en expresiones lingüísticas se expresa en el concepto de *grado de membresía*.

En un conjunto difuso se generaliza el concepto de membresía, permitiendo grados de pertenencia a los distintos conjuntos a considerar en el sistema. La función de pertenencia $\mu_A(x)$ de un conjunto difuso A es una función con recorrido en el segmento $[0, 1]$ de los números reales:

$$\mu_A(x) : U \subseteq \mathfrak{R} \rightarrow [0, 1] \quad (1.1.6)$$

En un conjunto tradicional, por ejemplo “el conjunto de todos los números mayores o iguales que 5”, los límites son abruptos, mientras que la transición entre ser y no ser miembro es gradual en un conjunto difuso. Un ejemplo de un conjunto difuso es el siguiente: la velocidad instantánea de un automóvil puede ser caracterizada por valores lingüísticos, como “Bajo”, “Medio” y “Alto”. Estos conjuntos se asocian con funciones de pertenencia como las mostradas en la Figura 1.1.2.

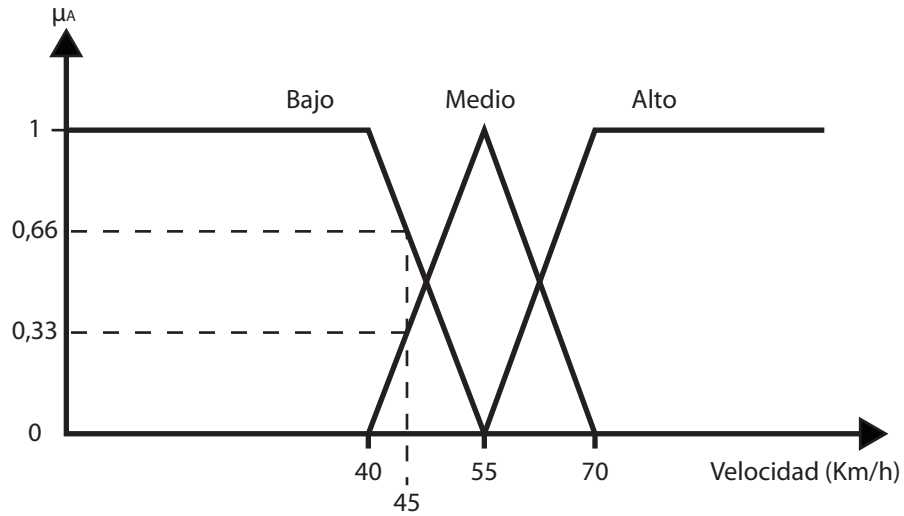


Figura 1.1.2: Ejemplo de funciones de pertenencia.

Si la velocidad de un automóvil es 45 Km/h , entonces existen grados de pertenencia 0,66, 0,33 y 0 a los conjuntos difusos “Bajo”, “Medio” y “Alto” respectivamente.

Operaciones básicas de lógica difusa Dados los conjuntos difusos A y B en el mismo universo X, con funciones de pertenencia μ_A y μ_B respectivamente, se pueden definir las siguientes operaciones básicas:

- Unión: La función de pertenencia de la unión de A y B se define como:

$$\mu_{A \cup B} = \text{máx}(\mu_A(x), \mu_B(x)) \quad (1.1.7)$$

- Intersección: La función de pertenencia de la intersección de A y B se define como:

$$\mu_{A \cap B} = \text{mín}(\mu_A(x), \mu_B(x)) \quad (1.1.8)$$

- Complemento: La función de pertenencia del complemento de A se define como:

$$\mu_{\bar{A}} = 1 - \mu_A(x) \quad (1.1.9)$$

Modelos difusos de Takagi y Sugeno

Estos modelos se basan en un conjunto de reglas heurísticas. Las premisas de las reglas del modelo corresponden a variables lingüísticas de las entradas del sistema, representadas por conjuntos difusos. Las consecuencias de las reglas son una relación de la salida con las entradas del sistema.

En la Figura 1.1.3 se muestra el diagrama de bloques de un modelo difuso típico.

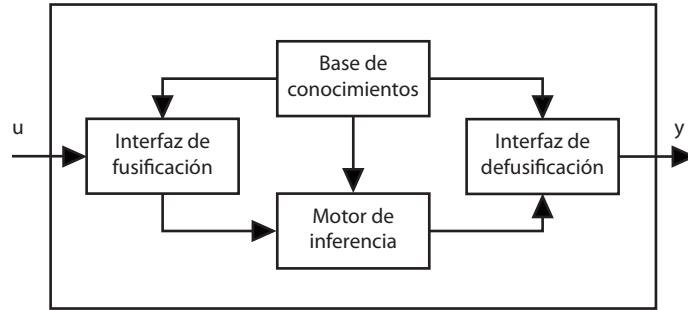


Figura 1.1.3: Diagrama de bloques de un sistema difuso.

Interfaz de fusificación Este elemento transforma las variables de entrada del modelo (u) en variables difusas. Para realizar este procedimiento en forma correcta, tienen que estar bien definidos los rangos de operación de cada variable de entrada, además de los conjuntos difusos asociados con sus respectivas funciones de pertenencia.

Base de conocimientos Contiene las reglas lingüísticas del control y la información referente a las funciones de pertenencia de los conjuntos difusos. Las variables de entrada en las premisas de cada regla son relacionadas por operadores “AND”. Las premisas están constituidas por funciones de salida en función de las variables de estado. Las reglas lingüísticas tienen la siguiente forma:

$$R_i: \text{If } X_1 \text{ is } A_{1i} \text{ and } \dots \text{ and } X_k \text{ is } A_{ki} \text{ then } Y_i = f_i(X_1, \dots, X_k)$$

En donde:

X_1, \dots, X_k son las variables de entrada o premisas de las reglas.

A_{1i}, \dots, A_{ki} son los conjuntos difusos asociados a las variables de entrada.

Y_i es la salida de la regla i .

f_i es una función que generalmente es lineal en los parámetros. Es decir, es de la forma $Y_i = p_o^i + p_1^i \cdot X_1 + \dots + p_k^i \cdot X_k$.

Motor de inferencia Realiza la tarea de calcular los grados de activación w_i de cada regla i a partir de los grados de pertenencia de las variables de entrada obtenidos en la etapa de fusificación.

Este calculo se puede realizar de dos formas. La primera es calculando el grado de activación w_i como la intersección de las funciones de pertenencia de los conjuntos difusos que forman la premisa de la regla:

$$w_i = \text{mín}(\mu_{1i}, \dots, \mu_{ki}) \quad (1.1.10)$$

La segunda es calculando el grado de activación w_i como la multiplicación de las funciones de pertenencia de los conjuntos difusos que forman la premisa de la regla:

$$w_i = \mu_{1i} \cdot \mu_{2i} \cdot \dots \cdot \mu_{ki} \quad (1.1.11)$$

Interfaz de defusificación Este elemento provee la salida del sistema a partir de los grados de activación y de las funciones de salida de cada regla.

La salida Y del modelo se obtiene ponderando la salida de cada regla por su respectivo grado de activación w_i , es decir:

$$Y = \frac{\sum_{i=1}^M (w_i \cdot Y_i)}{\sum_{i=1}^M w_i} \quad (1.1.12)$$

En donde M es el número de reglas del modelo y en donde w_i corresponde al grado de activación de la regla i .

En particular, los modelos dinámicos de tiempo discreto de Takagi y Sugeno basados en modelos ARX están dados por:

R_i : If $y(k-1)$ es A_{1i} and ... and $y(k-n_y)$ es $A_{n_y i}$ and $u(k-1)$ is B_{1i} and ... and $u(k-n_u)$ is $B_{n_u i}$ then $y_i(k) = a_1^i \cdot y(k-1) + \dots + a_{n_y}^i \cdot y(k-n_y) + b_1^i \cdot u(k-1) + \dots + a_{n_u}^i \cdot u(k-n_u) + c^i$

En donde a_j^i , b_j^i y c^i son parámetros de los modelos de las consecuencias.

Identificación de modelos difusos de Takagi - Sugeno

Un algoritmo de identificación difusa consiste en un procedimiento para encontrar un modelo difuso de un sistema en particular a partir de datos de entrada y salida de éste. Normalmente se utilizan dos conjuntos de datos para este propósito: uno de entrenamiento y otro de validación. El conjunto de entrenamiento se utiliza para encontrar el modelo, mientras que el de validación, como lo dice su nombre, se utiliza para validarlo. En la Figura 1.1.4 se muestra el esquema típico de un algoritmo de identificación difusa [3].

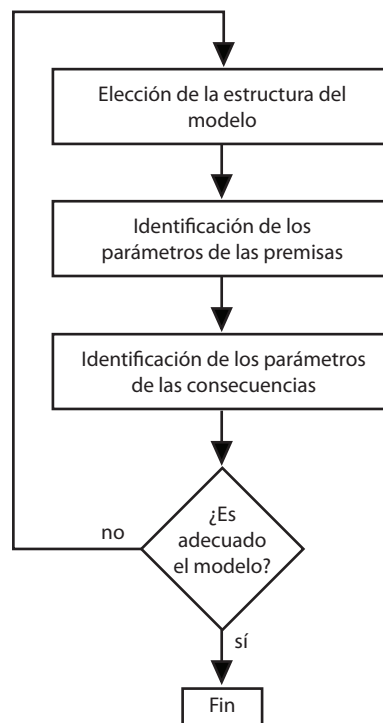


Figura 1.1.4: Método de identificación difusa.

Primero se debe elegir la estructura de un modelo inicial bajo algún criterio. Luego se deben identificar los parámetros de las premisas y finalmente se deben identificar los parámetros de las consecuencias.

A continuación se detalla cada una de las etapas.

Identificación de los parámetros de las premisas En esta etapa se deben formar los conjuntos difusos, a partir del conjunto de datos de entrenamiento, además de las premisas de las distintas reglas que formarán el modelo difuso.

El número óptimo de reglas y conjuntos difusos del modelo se determina haciendo una partición del universo de la variable de salida y luego proyectándolo sobre el espacio de entrada.

Para encontrar los conjuntos difusos en los que se particionará el espacio de entradas, y que además formarán parte de las premisas de las reglas, es necesario utilizar algún algoritmo de *clustering difuso*. Las premisas de las reglas surgirán a partir de las distintas combinaciones posibles entre los conjuntos difusos obtenidos por el *clustering*.

Los distintos algoritmos de *clustering difuso* existentes se basan en el criterio de particionar el espacio en conjuntos difusos de tal forma que cada conjunto, o *cluster*, sea lo más distinto posible a los otros, pero que sus elementos sean lo más parecido posible entre sí. En términos matemáticos, la varianza entre los distintos *clusters* debe ser máxima, pero ésta debe ser mínima al interior de cada *cluster*.

Lo anterior queda explicitado en la función objetivo (1.1.13).

$$S(c) = \sum_{k=1}^n \sum_{i=1}^c (\mu_{ik})^m \cdot (\|x_k - v_i\|^2 - \|v_i - \bar{x}\|^2) \quad (1.1.13)$$

En donde

n : Número de datos para el *clustering*.

c : Número de *clusters*.

x_k : k -ésimo vector de datos.

\bar{x} : Promedio de los datos.

v_i : Centro del *cluster* i -ésimo.

μ_{ik} : Grado de activación del k -ésimo dato perteneciente al i -ésimo *cluster*.

m : Peso ajustable.

Una vez realizado el *clustering*, los conjuntos difusos del espacio de salida deben ser proyectados sobre los conjuntos difusos A_j del espacio de entrada, como se muestra en la Figura 1.1.5.

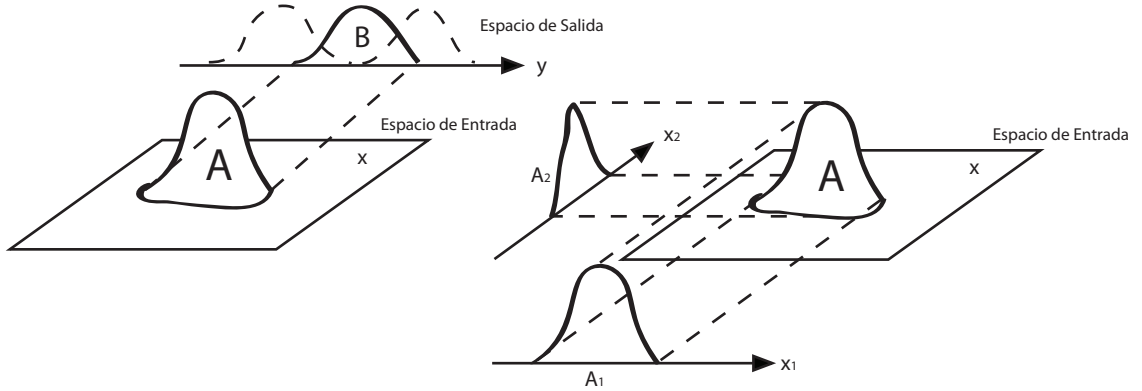


Figura 1.1.5: Proyección de clusters sobre espacio de entradas.

A partir de la proyección mostrada en la Figura 1.1.5, es posible construir la siguiente regla difusa:

$$R: \text{If } X_1 \text{ is } A_1 \text{ and } X_2 \text{ is } A_2 \text{ then } Y \text{ is } B$$

Identificación de los parámetros de las consecuencias Los parámetros de las consecuencias p_0^i, \dots, p_k^i generalmente se obtienen por el método de mínimos cuadrados, es decir, se minimiza el índice de error dado por (1.1.14):

$$e^2 = \sum_{p=1}^N (y_p - \hat{y}_p)^2 \quad (1.1.14)$$

En donde:

y_p es la salida del modelo.

\hat{y}_p es la salida del modelo difuso, considerando las mismas entradas del proceso.

N es el número de muestras.

Dado el conjunto de entrenamiento de N muestras de lecturas de las entradas y salidas del sistema, se calcula, para cada una de las muestras j , los grados de activación de cada una de las reglas del sistema. Según la definición dada anteriormente, esto corresponde a:

$$w_{i,j} = \text{mín} (\mu_{A_{1i}}(X_{1j}), \mu_{A_{2i}}(X_{1j}), \dots, \mu_{A_{ki}}(X_{1j})) \quad (1.1.15)$$

Se debe cumplir:

$$\begin{aligned} 1 \leq i \leq M \\ 1 \leq j \leq N \end{aligned} \tag{1.1.16}$$

En donde:

M es el número de reglas.

N es el número de muestras.

k es el número de variables.

Dado que se trata de un modelo de Takagi – Sugeno, la salida del modelo está dada por (1.1.17).

$$y_j = \frac{\sum_{i=1}^M (p_o^i + p_1^i \cdot X_{1j} + \dots + p_k^i \cdot X_{kj}) \cdot w_{ij}}{\sum_{i=1}^M (w_{ij})} \tag{1.1.17}$$

Se define (1.1.18).

$$B_{ij} = \frac{w_{ij}}{\sum_{i=1}^M (w_{ij})} \tag{1.1.18}$$

Considerando (1.1.18), la predicción de la salida j está dada por (1.1.19).

$$y_j = \sum_{i=1}^M (p_o^i \cdot B_{ij} + p_1^i \cdot B_{ij} \cdot X_{1j} + \dots + p_k^i \cdot B_{ij} \cdot X_{kj}) \tag{1.1.19}$$

Para realizar la identificación, se debe construir la matrix x' , que es de dimensiones $N \times M(k+1)$.

$$x' = \begin{bmatrix} B_{11}, \dots, B_{M1} & X_{11} \cdot B_{11}, \dots, X_{11} \cdot B_{M1} & \dots & X_{k1} \cdot B_{11}, \dots, X_{k1} \cdot B_{M1} \\ \vdots & \vdots & \vdots & \vdots \\ B_{1N}, \dots, B_{MN} & X_{1N} \cdot B_{1N}, \dots, X_{1N} \cdot B_{MN} & \dots & X_{kN} \cdot B_{1N}, \dots, X_{kN} \cdot B_{MN} \end{bmatrix} \tag{1.1.20}$$

A partir de (1.1.20), el vector de salida $y' = [y_1, \dots, y_N]^T$ se puede expresar según (1.1.21).

$$y' = x' \cdot P \tag{1.1.21}$$

En (1.1.21), $P = [p_0^1, \dots, p_0^M, p_1^1, \dots, p_1^M, \dots, p_k^1, \dots, p_k^M]^T$ es el vector de parámetros.

La identificación de los parámetros de las consecuencias se reduce a resolver la Ecuación (1.1.21) encontrando el vector P mediante un algoritmo de mínimos cuadrados.

$$\begin{aligned} y' &= x' \cdot P \quad / x'^T \cdot \\ x'^T \cdot y' &= x'^T \cdot x' \cdot P \\ P &= (x'^T x')^{-1} x'^T \cdot y' \end{aligned}$$

Elección de la estructura del modelo Una vez que se tienen calculados los parámetros de las consecuencias de las reglas del modelo, se puede alterar la estructura del modelo de tal forma de reducir el error.

Una posibilidad es generar todos los modelos resultantes de todas las combinaciones posibles del conjunto de regresores disponible. El problema es que eso puede resultar ser muy costoso desde el punto de vista computacional. Es conveniente recurrir a técnicas de selección de regresores para definir la estructura del modelo.

Es posible seleccionar sólo los regresores más significativos para la modelación mediante análisis de sensibilidad.

En general, la sensibilidad de las variables de un modelo no lineal está dada por (1.1.22).

$$\xi_i(x) = \frac{\partial f(x)}{\partial x_i} \quad (1.1.22)$$

La salida de un modelo difuso de Takagi – Sugeno es (1.1.23).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (1.1.23)$$

Combinando (1.1.22) y (1.1.23), se tiene que la sensibilidad de una variable de un sistema de Takagi – Sugeno está dada por (1.1.24).

$$\xi_i(x) = \frac{\sum_{r=1}^{N_r} \left(\frac{\partial w_r}{\partial x_i} y_r + \frac{\partial y_r}{\partial x_i} w_r \right) \sum_{r=1}^{N_r} w_r - \sum_{r=1}^{N_r} \left(\frac{\partial w_r}{\partial x_i} \right) \sum_{i=1}^{N_r} (w_r y_r)}{\left(\sum_{r=1}^{N_r} w_r \right)^2} \quad (1.1.24)$$

en donde

$$\frac{\partial w_r}{\partial x_i} = \frac{\partial \mu_i^r}{\partial x_i} \cdot \mu_1^r \cdots \mu_{i-1}^r \cdot \mu_{i+1}^r \cdots \mu_{n_y+n_u}^r \quad (1.1.25)$$

La sensibilidad de las variables de un modelo se obtiene evaluando (1.1.24) con el conjunto de datos de entrenamiento. Para comparar las sensibilidades de las variables de entrada del sistema, se propone el índice (1.1.26).

$$I_i = \mu_i^2 + \sigma_i^2 \quad (1.1.26)$$

En (1.1.26), μ_i y σ_i corresponden a la media y desviación estándar de las sensibilidades, respectivamente.

A continuación se explica el procedimiento realizado para obtener un modelo difuso mediante análisis de sensibilidad:

Paso 1. Obtención de modelo inicial. Se construye un modelo incluyendo los N regresores que se someterán a prueba para ver si son incluidos en la modelación. El modelo obtenido es denominado M_1 .

Paso n. Obtención de modelos por análisis de sensibilidad.

1. Si el modelo M_{n-1} contiene sólo un regresor, finalizar algoritmo.
2. Aplicar cálculo de sensibilidades del modelo M_{n-1} . Para eso, evaluar (1.1.24) con el conjunto de datos de entrenamiento.
3. Calcular índice (1.1.26) ($I_i = \mu_i^2 + \sigma_i^2$) a partir de la evaluación realizada en paso 2.
4. Eliminar regresor con menor índice I y recalcular modelo. El modelo obtenido es denominado M_n .
5. Continuar con paso $n + 1$.

En este trabajo se realizará un modelo de un aerogenerador mediante modelación puramente fenomenológica. Posteriormente, sobre el modelo fenomenológico, se aplicarán técnicas de identificación para obtener modelos de caja negra del mismo aerogenerador.

1.2. Objetivos y metodología de trabajo.

En este trabajo se presenta un nuevo método de identificación de modelos difusos. El nuevo método está basado en Algoritmos Genéticos y Optimización por Enjambre de Partículas, que, como se explicará más adelante, corresponden a técnicas de inteligencia computacional.

Los objetivos principales de este trabajo son presentar el nuevo método y comparar la nueva estrategia de identificación con otras estrategias de identificación de sistemas difusos ya existentes y con modelos lineales equivalentes.

Para someter a prueba la nueva estrategia, se identifica un sistema aerogenerador, por lo que en este trabajo se mejora y actualiza el desarrollo de un simulador existente de un aerogenerador doble alimentado.

Para efectos de este trabajo, se asume que el simulador desarrollado es el sistema real sobre el cual se trabaja. Se realizan simulaciones de tiempo continuo y se toman datos de manera discreta para posteriormente obtener un modelo de caja negra del sistema, mediante diferentes técnicas de identificación.

La modelación del sistema está basada en sistemas de ecuaciones diferenciales y algebraicas. El sistema es no-lineal, de variable y tiempo continuo. Dado que los aerogeneradores son alimentados con la energía proveniente del viento, cuya velocidad es una variable estocástica, el aerogenerador es un sistema que contiene variables estocásticas.

Se realiza un análisis de sensibilidad de los parámetros de ajuste del nuevo método y se obtienen modelos del aerogenerador. Finalmente se contrastan los modelos obtenidos mediante el nuevo método con otros modelos difusos obtenidos mediante métodos existentes y con modelos lineales autorregresivos de variable exógena.

1.3. Aerogenerador

1.3.1. Motivación

En los últimos años ha crecido el interés de generar energía eléctrica a partir de fuentes energéticas no convencionales. Esto se debe al aumento en los precios de los combustibles fósiles y a que existe una mayor conciencia social sobre el impacto ambiental producido por la generación por medios convencionales. En este contexto, la generación eólica se ha posicionado como una fuente energética viable.

La Unión Europea (UE) es el líder mundial en lo que se refiere a generación eólica, tanto por el porcentaje de penetración de esta tecnología en su matriz energética, como por la experiencia acumulada por años de investigación y desarrollo [10]. De acuerdo a la Asociación Europea de Energía Eólica (EWEA, por sus siglas en inglés), desde el año 2004 la presencia de generación eólica en la matriz energética mundial ha aumentado en forma dramática. A finales de 2003 se contaba con una capacidad instalada de 40.000 MW, mientras que a finales de 2007 la capacidad instalada era de 94.000 MW, lo que significa un aumento anual promedio de un 25 %. A finales de 2007, el 60 % de la capacidad mundial estaba instalada en Europa [10].

Se espera que el nivel de penetración de esta tecnología aumente aún más. En marzo de 2007 los jefes de estado de los países miembros de la UE se plantearon como meta que en 2020 el 20 % de la energía de la matriz energética europea debería provenir de medios de generación no convencionales [10]. Por otra parte, Estados Unidos aumentó su capacidad instalada de generación eólica en 8.500 MW durante 2008, lo que significó un aumento de un 50 % de la presencia de este tipo de generación en su matriz energética, además de posicionarse como el país con mayor capacidad instalada en el mundo, por sobre Alemania [28]. Las políticas energéticas estadounidenses actuales establecen como objetivo que en 2030 el 20 % de su demanda energética debe ser satisfecha mediante generación eólica [28].

Estas cifras son muy alentadoras al momento de evaluar el panorama actual de la generación eólica, sin embargo se podría llegar a la conclusión errónea que esta tecnología ya está madura, lo que no es cierto [10].

Los aerogeneradores pueden parecer ser máquinas simples, pero existen requerimientos que hacen que esta rama de la ingeniería sea distinta a cualquier otra [10]:

- La máquina tiene que operar como generador, en forma autónoma, y debe proveer a la red mucho más que simplemente potencia activa; como por ejemplo potencia reactiva y control de frecuencia en redes muy pequeñas.
- El viento es variable a escalas de tiempo que van de los segundos a los años. Eso introduce incertidumbre a todo el sistema. Desde las cargas mecánicas hasta la producción de energía está sujeta a esa incertidumbre.
- La tecnología tiene que competir en costo de producción de energía contra otras fuentes de energía renovable no convencional y también contra la generación convencional.

A principios de 2008, cuando el precio de cada barril de petróleo se encumbraba por los 147 dólares estadounidenses, la generación eléctrica con viento resultaba aproximadamente un 10 % más cara que la generación convencional [10]. A pesar de existir mejoras tecnológicas en el diseño y gestión operativa de las turbinas y granjas eólicas, la disminución en el precio del petróleo, motivada por la recesión económica internacional que se inició en 2008, ha hecho aumentar la brecha de precios entre ambos tipos de generación, a favor de los métodos convencionales. Dado que la generación eólica es un producto sustituto del petróleo, una baja en el precio del crudo desincentiva la inversión en generación no convencional. En este contexto, los trabajos de investigación y desarrollo relacionados con turbinas y granjas eólicas deben tener como objetivo principal contribuir a la disminución de esa brecha, con el fin de aumentar la competitividad económica de los métodos de generación no convencional con respecto a las tecnologías convencionales [18].

La EWEA ha identificado cuatro áreas de investigación y desarrollo para asegurar una correcta implementación de la visión que se ha planteado para el año 2030 del sector energético eólico [10]. Dichas áreas son:

1. Condiciones de viento.
2. Tecnología de aerogeneradores.
3. Integración de energía eólica.
4. Despliegue y operación de aerogeneradores marítimos.

Una de las principales preocupaciones de la EWEA es que los esfuerzos empleados por la UE en investigación, desarrollo y financiamiento, en este momento, son insuficientes para satisfacer los

objetivos europeos de crecimiento de este tipo de generación.

Como en todo proyecto económico, para que un proyecto de instalación de aerogeneradores resulte atractivo desde el punto de vista financiero, debe tener un valor presente neto (VPN) al menos positivo. Los costos de los proyectos de generación eólica están dominados por el costo de la turbina eólica [10, 18]. La inversión total en una turbina promedio instalada en Europa es de aproximadamente €1,23 millones/MW, incluyendo los costos de instalación, conexión a la red y consultoría. Los costos se dividen aproximadamente como sigue: 76 %: turbina; 9%: conexión a la red; 7%: obras civiles asociadas. El 8 % restante corresponde a los sistemas de control, al terreno de emplazamiento y a otros costos menores. Los costos, y su correspondiente distribución, son diferentes en otras partes del mundo, porque los principales fabricantes de aerogeneradores están ubicados en países de la UE. Una vez que la turbina se encuentra instalada, los costos de generación se reducen a los costos operacionales y de mantenimiento de la turbina, lo que no ocurre en generación convencional. En plantas convencionales se debe incurrir en los costos del combustible, así como en la compra de bonos de carbono para legalizar la emisión de dióxido de carbono a la atmósfera (tratado de Kyoto). El viento es un bien libre, por lo que no es necesario pagar por utilizarlo y la generación eólica no produce emisiones de dióxido de carbono.

En [18], David Molenaar plantea su visión acerca del rol que debe cumplir la comunidad de ingenieros de control en el desarrollo tecnológico de aerogeneradores. Molenaar sostiene que para maximizar el VPN se deben lograr los siguientes objetivos:

- Disminuir los costos de inversión, operación y mantenimiento
- Lograr que la vida útil técnica del proyecto sea al menos igual al horizonte de evaluación considerado en el estudio económico.
- Lograr una conversión eficiente de la energía para maximizar la producción dadas ciertas condiciones de viento.

La baja en los costos de inversión está asociada a la creación de diseños más eficientes desde el punto de vista aerodinámico, eléctrico y mecánico, mientras que los otros dos puntos están asociados tanto a mejoras en el diseño como al mejoramiento de la gestión de las plantas y al diseño de estrategias de control adecuadas.

Desde el punto de vista de control de sistemas, en una turbina moderna, las variables manipula-

das son el ángulo de ataque de palas con respecto al viento y la velocidad de giro de la turbina [11]. Más adelante se profundizará en este tema.

En particular, al modificar el ángulo de ataque, se puede frenar la turbina en los casos en que su velocidad de giro es mayor a la nominal. De esta forma se protege a la turbina de posibles daños estructurales por las grandes fuerzas centrípetas que aparecen sobre el rotor y las palas, aumentando su vida útil. Modificando esta misma variable, se puede variar el torque aplicado sobre el rotor. Así se puede mantener acotado el esfuerzo mecánico al que está sometido el sistema. La limitación sobre el esfuerzo mecánico está directamente asociada a la disminución en los costos de mantención, porque las piezas se desgastarán menos y es posible disminuir la cantidad de mantenciones programadas en un año [18].

Como se explicará más adelante, al manipular la velocidad de giro es posible maximizar la potencia generada para un amplio rango de velocidades de viento, así como mejorar el factor de potencia de la planta [11, 18].

Según Molenaar, los expertos en energía eólica sostienen que no es atractivo implementar estrategias de control avanzado en este tipo de plantas, a menos que se logre implementar control óptimo basado en modelos [18]. La razón por la cual resultaría atractiva una implementación de esta naturaleza es por el alto grado de estocasticidad que aporta el viento al sistema. Considerando que el viento es la variable más importante del sistema y dado que es una variable incontrolable, si se lograra crear una estrategia de control capaz de anticiparse a lo que ocurrirá en el futuro, sería un gran aporte al objetivo de maximización de potencia.

Molenaar también sostiene que dada la complejidad de la planta y su comportamiento altamente no-lineal, sería conveniente desarrollar modelos no-lineales que representen la dinámica de la planta para posteriormente realizar predicciones de su comportamiento [18]. Sin embargo, cabe recordar que para la implementación de un controlador predictivo, no es suficiente disponer de un buen modelo de la planta. También es necesario desarrollar un sistema predictor de las condiciones de viento, que es la principal fuente de incertidumbre en el sistema.

Los aerogeneradores de un mismo tipo pueden ser modelados por sistemas de ecuaciones de estructura similar, sin embargo identificar los parámetros correspondientes a cada unidad en particular puede resultar en un procedimiento complicado dada la no-linealidad de las ecuaciones que modelan el sistema.

En este trabajo se utilizarán las ecuaciones típicas que se usan para modelar aerogeneradores para desarrollar un simulador. Posteriormente se calibrará un modelo no-lineal difuso mediante un nuevo método basado en algoritmos evolutivos. Este método permitiría obtener un modelo no-lineal a partir de datos reales medidos en planta. De esta forma sería posible obtener fácilmente modelos no-lineales para cada uno de los aerogeneradores de una granja eólica, posibilitando la implementación de control predictivo no-lineal hecho a medida para cada unidad.

A continuación se harán comentarios acerca de las distintas tecnologías disponibles de aerogeneradores, luego se presentarán modelos matemáticos no-lineales de aerogeneradores y su implementación en el simulador. Finalmente se explicará el nuevo método de identificación difusa y, finalmente, se presentarán los resultados de la identificación difusa realizada sobre el modelo implementado.

1.3.2. Descripción de un aerogenerador

Hasta la aparición de la máquina a vapor en el siglo XIX, la única energía de origen no animal para la realización de trabajo mecánico provenía del agua o del viento [11]. La utilización de molinos de viento se remonta al siglo 17 antes de Cristo, cuando Hammurabi utilizó estos dispositivos para la molienda del trigo y para irrigar las llanuras de Mesopotamia. Durante siglos se ha acumulado mucha experiencia en el manejo de estas máquinas.

Los aerogeneradores son una versión moderna de los antiguos molinos de viento. A diferencia de los molinos, en las turbinas se acopla un generador eléctrico al rotor de la máquina con el fin de convertir la energía que aporta el viento en energía eléctrica.

Las turbinas actuales se pueden clasificar en dos grandes grupos: las turbinas de eje horizontal y las turbinas de eje vertical. Las primeras son las más comunes, porque se encuentran más desarrolladas tanto desde el punto de vista técnico como comercial [11]. Por esa razón se trabajará con este tipo de turbinas.




Figura 1.3.1: Turbina de eje horizontal y de eje vertical.

Existen diferentes tecnologías de turbinas horizontales, pero, independiente de la tecnología utilizada, los subsistemas que forman la turbina son comunes. En la Figura 1.3.2 se muestra un diagrama de bloques típico de una turbina eólica y a continuación se hace una descripción de cada bloque. Es importante destacar que en este sistema los bloques se encuentran acoplados entre ellos en forma bidireccional, por lo que las técnicas utilizadas tradicionalmente en ingeniería de control y en la validación de modelos no siempre funcionan [18].

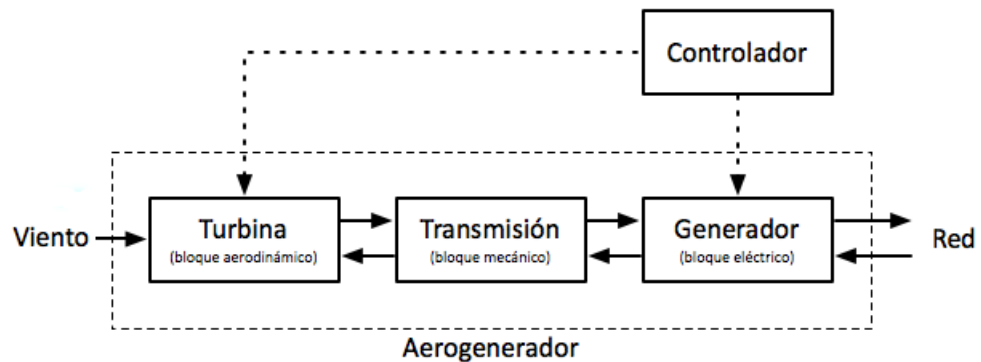


Figura 1.3.2: Diagrama de bloques de un aerogenerador.

1.3.2.1. Bloque viento

Este bloque representa al viento, que es la fuente de energía del sistema. Desde el punto de vista de análisis y modelación de sistemas, el viento es considerado un proceso estocástico no controlable, porque es un fenómeno que presenta una dinámica incierta y que es imposible de manipular de alguna forma. Por esa razón, a pesar de ser la fuente de energía de la planta, y por ende una de las variables relevantes del sistema, el viento es considerado como una perturbación medida.

Existe conocimiento estadístico acerca del comportamiento del viento. Se sabe que la función densidad de probabilidad que describe la velocidad del viento a una altura determinada sigue una distribución de Weibull [11]. El conocimiento de esta función permite tener una idea de qué tan apto es un terreno para emplazar una turbina eólica o para tener una proyección de cuál es la potencia generada esperada en el futuro. Tanto para cumplir con los requerimientos de potencia del despacho económico como para el funcionamiento de estrategias de control predictivo, es necesario disponer de predicciones de la velocidad del viento con diferente horizonte de predicción, según la aplicación. La información estadística es insuficiente para hacer predicciones adecuadas para estas aplicaciones. Es necesario recurrir a modelos de predicción más complejos para satisfacer esa necesidad.

1.3.2.2. Bloque aerodinámico

Este bloque representa a la turbina. La turbina es una parte compleja del sistema. Es el mecanismo que interactúa con el viento y debe ser diseñado de forma muy cuidadosa para que se desempeñen de la forma que se desea.

En sistemas de alta potencia es rentable instalar un mecanismo que permita la inclinación de las palas de la turbina. Este mecanismo ofrece una serie de ventajas, entre las cuales se encuentran las siguientes [11]:

1. La variación del ángulo de inclinación de las palas permite mejorar el aprovechamiento de la energía contenida en el viento para un amplio rango de velocidades.
2. Se disminuyen las cargas mecánicas en las palas y las demás partes de la turbina.
3. Este mecanismo permite frenar la turbina de forma aerodinámica en caso de embalamiento. Esto es importante, porque las tensiones mecánicas que se generan en ese estado son tan fuertes, que podrían llegar a destruir la planta.

4. Disminución del ruido producido por la máquina.

Básicamente, al variar el ángulo con que las palas enfrentan el viento, es posible controlar el torque que se aplica sobre el rotor al que está acoplada la turbina y, de esa forma, realizar control de la potencia generada. Para lograr efecto, con un sistema hidráulico se hace girar las palas sobre su eje longitudinal.

Existen dos técnicas de control de potencia basadas en la inclinación de las palas: control activo de potencia por pérdida aerodinámica (active stall control) y control de potencia por variación del ángulo de ataque (pitch control).

Las turbinas que utilizan control activo de potencia por pérdida aerodinámica (active stall control) utilizan palas con un perfil aerodinámico diseñado de tal forma que al variar el ángulo de inclinación de las palas, éstas pierdan parte de su capacidad de sustentación aerodinámica. De esta forma el viento es incapaz de hacer rotar el eje del aerogenerador por sobre un límite de velocidad que es dependiente del ángulo de inclinación de las palas. Esta técnica se utiliza para frenar la turbina cuando ésta supera su velocidad de giro nominal. Así se busca disminuir el torque en el rotor y la fuerza centrípeta que afecta a las palas, protegiendo a la turbina de sobrecargas mecánicas y manteniendo acotada la producción de potencia, con el fin de proteger los equipos eléctricos del sistema.

En control de potencia por variación del ángulo de ataque (pitch control), lo que se busca es llevar a las palas a un ángulo de ataque óptimo con respecto a las condiciones actuales de viento para optimizar el rendimiento del sistema cuando la velocidad del viento es menor a la nominal. Si se supera la velocidad de viento nominal, se rotan las palas en sentido contrario y la máquina se frena por pérdida de sustentación aerodinámica, tal como ocurre en stall control. De esa forma también es posible proteger a la máquina de vientos muy fuertes con esta tecnología.

1.3.2.3. Bloque mecánico

El bloque mecánico básicamente representa el acople mecánico entre la turbina y el generador de la máquina. El acople consiste en una caja multiplicadora de engranajes. Es necesario que el acople sea realizado a través de este tipo de mecanismo, porque la velocidad nominal de la turbina es menor que la velocidad nominal del generador. La turbina gira a velocidades del orden de 20 – 30 [rpm], mientras que un generador de inducción típico de 4 polos lo hace a 1500 [rpm]. La caja

multiplicadora consiste en un arreglo que engranajes que multiplican la velocidad de la turbina aproximadamente unas 80 veces para que el acople mecánico se realice en forma correcta.

1.3.2.4. Bloque eléctrico

Para convertir la energía mecánica del rotor de la turbina en energía eléctrica, se utiliza un generador. A pesar que por lo general es poco común la utilización de generadores asincrónicos de inducción en la industria, los aerogeneradores son de las pocas plantas en donde son muy comunes. La razón de la utilización de este tipo de generadores es que son más baratos, más pequeños y más livianos que los generadores sincrónicos. Además requieren de menos mantenimiento que los otros.

Dependiendo de la forma de conexión eléctrica del generador y del tipo de generador utilizado, éste puede ser de velocidad fija o velocidad variable.

Los aerogeneradores de velocidad fija consisten, básicamente, en un sistema multiplicador y un generador asíncrono conectado directamente a la red. Típicamente se utilizan generadores tipo jaula de ardilla. Además se incorporan bancos de condensadores para hacer compensación de energía reactiva. La velocidad de giro del rotor de la máquina eléctrica dependerá de la velocidad síncrona impuesta por la red y del deslizamiento propio del generador. Esta consideración es muy importante, porque el generador y la turbina están acoplados mecánicamente, por lo que el funcionamiento del bloque eléctrico afectará al funcionamiento del bloque aerodinámico y viceversa. Típicamente los aerogeneradores son capaces de generar una potencia de unas pocas unidades de megawatts, lo que es despreciable con respecto a la potencia que circula por la red eléctrica. Por esa razón la inercia de la red eléctrica prevalece por sobre la inercia de la turbina. El generador gira a la velocidad fija impuesta por la frecuencia de la red y el deslizamiento, mientras que la turbina gira a una velocidad fija proporcional a la velocidad del generador, independiente de la velocidad del viento. Si el bloque aerodinámico no estuviese acoplado al eléctrico, la velocidad de giro de la turbina no sería fija y sería dependiente de la velocidad del viento. Por esa razón se produce mucha tensión mecánica en las distintas partes de la máquina y resulta necesario utilizar control activo de potencia por pérdida aerodinámica para limitar la potencia generada cuando hay vientos muy fuertes. De no ser así, el esfuerzo mecánico que podría llegar a producirse sería de tal magnitud que incluso el aerogenerador podría llegar a destruirse.

En aerogeneradores de velocidad fija, normalmente el único control que se realiza es la limitación de potencia por pérdida aerodinámica, compensación reactiva mediante la conexión y desconexión

controlada de bancos de condensadores. La magnitud de la potencia generada a velocidades de viento menores a la nominal no es controlada. Ésta depende de la velocidad del viento, por lo que también es aleatoria.

En los últimos años se ha vuelto común la construcción de generadores de velocidad variable con control de potencia por variación del ángulo de ataque (pitch control). Este diseño ofrece varias ventajas que el caso explicado antes, a pesar de ser una tecnología más compleja y costosa. Una de las ventajas más importantes es la posibilidad de optimizar la generación de potencia a velocidades de viento menores a la nominal, porque al variar la velocidad de giro es posible llevar a la máquina a puntos de operación en que el rendimiento aerodinámico es más alto. Otra ventaja es la disminución sustancial de los esfuerzos mecánicos, efecto que se logra al adaptar la velocidad de giro del generador de acuerdo a la velocidad instantánea del viento.

Existen diferentes técnicas para lograr variar la velocidad del generador. Si se opta por trabajar con generadores asíncronos, una forma relativamente sencilla de control de velocidad consiste en trabajar con máquinas de rotor embobinado y variar el deslizamiento del generador. Al manipular el deslizamiento, es posible controlar la velocidad de giro de la máquina. Es posible variar el deslizamiento conectando resistencias variables al embobinado del rotor. De esta forma se puede variar el deslizamiento entre un 1 % y 10 %. Este sistema requiere de compensación de potencia reactiva mediante bancos de condensadores.

Otra opción es el uso de generadores de doble inducción. En este caso se utiliza un generador asíncrono con su estator conectado directamente a la red y su rotor conectado a dos convertidores de frecuencia. Esta configuración permite variar la velocidad de giro en torno a la velocidad nominal del generador sin tener que conectar el estator de la máquina a la red a grandes convertidores de frecuencia. Como sólo una parte de toda la potencia que circula por la máquina pasa por los convertidores, el costo de este sistema es competitivo. Con este sistema la potencia de salida no tiene fluctuaciones y, a velocidades de viento altas, el rotor también genera energía.

En la actualidad la mayoría de fabricantes de aerogeneradores de gran potencia están optando por diseños que utilizan el concepto de aerogenerador de velocidad variable con generador de doble inducción y control de potencia por variación del ángulo de ataque. Considerando esta tendencia, en este trabajo se optó por la utilización de este tipo de aerogeneradores.

En el siguiente capítulo se presentarán modelos matemáticos de las distintas partes que compo-

nen un aerogenerador.

Capítulo 2

Modelación de un aerogenerador

A simple vista un aerogenerador podría parecer una planta simple de trabajar y modelar. Sin embargo, tal como se comentó anteriormente, los aerogeneradores presentan una dinámica no-lineal, lo que combinado a la característica estocástica del viento, convierte a estas plantas en un sistema complejo de representar.

En este trabajo se tomará como base un modelo analítico existente, basado en ecuaciones diferenciales. El modelo fue utilizado por Iov, Hansen, Sørensen y Blaabjerg para desarrollar un simulador que se encuentra disponible para uso libre [15]. Éste fue recopilado y extendido por los autores para la programación de un simulador programado en MATLAB. En este trabajo dicho modelo fue comparado otro encontrado en la literatura, pero cuyo simulador no se encuentra disponible [22]. Ambos modelos no coinciden totalmente en estructura, por lo que se procedió a revisar las ecuaciones en forma exhaustiva para comprobar la validez del simulador de acceso libre.

A continuación se muestran las ecuaciones revisadas que describen cada bloque:

2.1. Bloque aerodinámico

La ecuación que describe al torque aerodinámico producido por la turbina del generador es la siguiente:

$$T_{wt} = \frac{1}{2} \pi \rho R^3 v^2 C_T(\lambda, \theta) \quad (2.1.1)$$

En donde:

ρ : Densidad del aire.

R : Radio de la turbina.

v : Velocidad instantánea del viento.

C_T : Coeficiente de torque.

El coeficiente de torque (C_T) es una función no-lineal que depende del diseño de la turbina. Tanto en turbinas que utilizan *Active Stall Control* y *Pitch Control*, el coeficiente de potencia depende de la razón entre la velocidad en las puntas de las palas y la velocidad del viento (λ : tip speed ratio), además del ángulo de inclinación de las palas (θ : pitch angle). En la Figura 2.1.1 se muestra la superficie que describe el coeficiente de torque de una turbina en particular. Un buen modelo de un aerogenerador requiere del mayor conocimiento posible de esta función.




Figura 2.1.1: Gráfico del coeficiente de torque de una turbina eólica.

La razón entre la velocidad en las puntas de las palas y la velocidad del viento está dada por:

$$\lambda = \frac{\Omega R}{v} \quad (2.1.2)$$

En donde Ω es la velocidad angular de la turbina.

Cabe recordar que la turbina está mecánicamente acoplada al generador a través de una caja reductora. La velocidad de giro, por lo tanto, dependerá de la interacción física entre los tres mecanismos, efecto que debe ser considerado en la modelación del sistema.

Típicamente los aerogeneradores operan sólo en cierto rango de velocidades de viento. Este rango depende del modelo de aerogenerador utilizado, pero usualmente la velocidad mínima de viento necesaria para el funcionamiento de un aerogenerador es de aproximadamente 5^{m/s}, mientras que la velocidad máxima de operación es de aproximadamente 25^{m/s}. La mayoría de los aerogeneradores están diseñados para operar a una velocidad nominal de viento en torno a los 15^{m/s}.

Normalmente se comienza a aplicar *active stall control* cuando el viento sobrepasa la velocidad nominal para la que la planta está diseñada. Por esa razón la potencia se mantendrá acotada para velocidades de viento por sobre la nominal.

De esta forma, se distinguen cuatro modos de operación en un aerogenerador:

1. Cuando la velocidad del viento es menor que el umbral mínimo de funcionamiento, la potencia generada es cero.
2. Cuando la velocidad del viento es mayor que el umbral de funcionamiento y menor que la velocidad nominal de viento, la potencia generada queda determinada por (3.2.1).
3. Cuando la velocidad del viento sobrepasa la velocidad de viento nominal, comienza a actuar el limitador de potencia. De esta forma, para velocidades de viento por sobre la nominal, el aerogenerador entregará potencia nominal.
4. Cuando la velocidad del viento sobrepasa el umbral máximo de funcionamiento, se detiene completamente la turbina para protegerla de daños. En este estado la potencia generada es cero.

En la Figura 2.1.2 se muestra un diagrama de bloques de la sección aerodinámica de un aerogenerador.




Figura 2.1.2: Bloque aerodinámico del aerogenerador.

2.2. Bloque mecánico

El modelo mecánico equivalente de la caja multiplicadora se muestra en la Figura 2.2.1. El modelo corresponde a un modelo de tres cuerpos en donde un cuerpo de gran tamaño representa a la turbina del aerogenerador, otros cuerpos representan los engranes de la caja de cambios, mientras que un último cuerpo representa al rotor del generador.




Figura 2.2.1: Modelo del sistema mecánico [15].

Considerando los factores de rigidez y amortiguamiento de ambos ejes, las ecuaciones de movimiento del sistema son las siguientes:

$$\begin{aligned}
 T_{wtr} &= J_{wtr} \frac{d\Omega_{wtr}}{dt} + D_{wtr} \Omega_{wtr} + k_{swtr} (\theta_{wtr} - \theta_1) \\
 T_1 &= J_1 \frac{d\Omega_1}{dt} + D_{wtr} \Omega_1 + k_{swtr} (\theta_1 - \theta_{wtr}) \\
 T_2 &= J_2 \frac{d\Omega_2}{dt} + D_{gen} \frac{d\Omega_2}{dt} + k_{sgen} (\theta_2 - \theta_{gen}) \\
 -T_{gen} &= J_{gen} \frac{d\Omega_{gen}}{dt} + D_{gen} \Omega_{gen} + k_{sgen} (\theta_{gen} - \theta_2)
 \end{aligned}$$

En donde:

T_{wtr} : Torque producido por la turbina.

J_{wtr} : Momento de inercia de la turbina.

Ω_{wtr} : Velocidad angular de la turbina.

k_{swtr} : Factor de elasticidad que indica la rigidez de torsión del eje en la zona de la turbina.

D_{wtr} : Factor de amortiguamiento del eje en la zona de la turbina.

T_{gen} : Torque eléctrico producido por el generador.

J_{gen} : Momento de inercia del rotor del generador.

Ω_{gen} : Velocidad angular del generador.

k_{sgen} : Factor de elasticidad que indica la rigidez de torsión del eje en la zona del generador.

D_{gen} : Factor de amortiguamiento del eje en la zona del generador.

T_1 : Torque de entrada de la caja de cambios.

T_2 : Torque de salida de la caja de cambios.

La velocidad angular se relaciona con la posición angular a través de las siguientes ecuaciones:

$$\begin{aligned}\frac{d\theta_{wtr}}{dt} &= \Omega_{wtr} \\ \frac{d\theta_1}{dt} &= \Omega_1 \\ \frac{d\theta_2}{dt} &= \Omega_2 \\ \frac{d\theta_{gen}}{dt} &= \theta_{gen}\end{aligned}$$

Además la razón de transformación de la caja de cambios relaciona el torque de entrada con el de salida de la siguiente forma:

$$T_2 = \frac{1}{k_{gear}} T_1 \quad (2.2.1)$$

La caja de cambios también relaciona las velocidades angulares de cada eje de la siguiente forma:

$$\Omega_2 = k_{gear}\Omega_1 \quad (2.2.2)$$

En donde k_{gear} es la razón de transformación de la caja de cambios.

En la Figura 2.2.2 se muestra un diagrama de bloques del bloque mecánico del aerogenerador, donde se señalan claramente entradas y salidas.



Figura 2.2.2: Bloque mecánico del aerogenerador.

2.3. Bloque eléctrico

En la Figura 2.3.1 se muestra el diagrama de fases de la una maquina de inducción de doble alimentación.




Figura 2.3.1: Diagrama de fases máquina de inducción.

Dado que este tipo de máquinas tiene partes móviles, es conveniente realizar un cambio de variables en el sistema de referencia para simplificar el análisis. Se utilizará un sistema de referencia

conocido como dq , que consiste en dos ejes ortogonales que rotan a una velocidad arbitraria ω_g . El eje d se denomina eje directo, mientras que el eje q se denomina eje en cuadratura. En este sistema, los enrollados de la máquina son reemplazados por enrollados virtuales equivalentes en el nuevo sistema. Al combinar los efectos de dichos enrollados, se recupera el efecto físico generado por la combinación de los enrollados originales, por lo que el modelo representará el funcionamiento de la máquina de forma adecuada, si se realizan las transformaciones correctas.

En la Figura 2.3.2 se muestra como está formado el sistema de referencia dq . Se toma como punto de referencia estático el eje correspondiente a la fase A del estator. El ángulo θ se utiliza para representar la posición del eje correspondiente a la fase a del rotor con respecto al eje correspondiente a la fase A del estator. El ángulo θ_r se utiliza para representar la posición del eje correspondiente a la fase a del rotor con respecto al eje d del sistema de referencia dq .




Figura 2.3.2: Sistema de referencia dq .

Si se supone un sistema eléctrico trifásico equilibrado, es posible realizar el cambio de variables desde el sistema trifásico abc al sistema dq , y viceversa, utilizando las siguientes matrices de transformación para las corrientes:

$$\begin{bmatrix} i_d \\ i_q \end{bmatrix} = \begin{bmatrix} \cos \theta & \cos \left(\theta - \frac{2\pi}{3} \right) & \cos \left(\theta + \frac{2\pi}{3} \right) \\ -\sin \theta & -\sin \left(\theta - \frac{2\pi}{3} \right) & -\sin \left(\theta + \frac{2\pi}{3} \right) \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \quad (2.3.1)$$

$$\begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} = \begin{bmatrix} \cos \theta & -\sin \theta \\ \cos \left(\theta - \frac{2\pi}{3} \right) & -\sin \left(\theta - \frac{2\pi}{3} \right) \\ \cos \left(\theta + \frac{2\pi}{3} \right) & -\sin \left(\theta + \frac{2\pi}{3} \right) \end{bmatrix} \begin{bmatrix} i_d \\ i_q \end{bmatrix} \quad (2.3.2)$$

Estas transformaciones también son válidas para los voltajes.

Para simplificar el análisis y simulación del sistema, se aplicó la transformación dq a las variables de entrada y se realizó la modelación de la máquina en el sistema de referencia dq .

Las variables de entrada de este bloque del sistema corresponden al vector de voltajes dq de estator (v_s), vector de voltajes dq de rotor (v_r) y la velocidad de giro del rotor (ω_r).

Las variables de salida del sistema corresponden al vector de corrientes dq de estator (i_s), vector de corrientes dq de rotor (i_r) y al torque eléctrico (T_e).

En el sistema dq , las variables v_s , v_r , i_s e i_r pueden ser representadas por una relación vectorial, ya que pueden expresarse como combinaciones lineales de la base vectorial del sistema de referencia dq . En notación compleja, las variables mencionadas se pueden expresar de la siguiente forma:

$$v_s = v_{sd} + j \cdot v_{sq}$$

$$v_r = v_{rd} + j \cdot v_{rd}$$

$$i_s = i_{sd} + j \cdot i_{sq}$$

$$i_r = i_{rd} + j \cdot i_{rd}$$

En el sistema de referencia dq , las ecuaciones eléctricas de estator y rotor son, respectivamente:

$$v_s = R_s \cdot i_s + \frac{d\Psi_s}{dt} + j \cdot \omega_g \cdot \Psi_s \quad (2.3.3)$$

$$v_r = R_r \cdot i_r + \frac{d\Psi_r}{dt} + j \cdot (\omega_g - \omega_r) \cdot \Psi_r \quad (2.3.4)$$

En donde:

ω_g : Velocidad angular del sistema de referencia dq

ω_r : Velocidad angular del rotor

Ψ_s : Flujo magnético estator

Ψ_r : Flujo magnético rotor

R_s : Resistencia de estator

R_r : Resistencia de rotor

Si se desprecia la saturación del hierro, se tienen las siguientes expresiones para los flujos de la máquina:

$$\Psi_s = L_s \cdot i_s + L_m \cdot i_r \quad (2.3.5)$$

$$\Psi_r = L_m \cdot i_s + L_r \cdot i_r \quad (2.3.6)$$

En donde:

L_s : Inductancia de bobinado de estator

L_r : Inductancia de bobinado de rotor

L_m : Inductancia mutua

Los flujos también se pueden expresar como combinación lineal de dos componentes vectoriales basadas en los ejes del sistema dq :

$$\Psi_s = \Psi_{sd} + j \cdot \Psi_{rq} \quad (2.3.7)$$

$$\Psi_r = \Psi_{rd} + j \cdot \Psi_{rq} \quad (2.3.8)$$

Reemplazando las expresiones vectoriales de los voltajes, corrientes y flujos en las ecuaciones (2.3.3) y (2.3.4), se obtienen las siguientes expresiones:

$$v_{sd} = R_s \cdot i_{sd} + \frac{d\Psi_{sd}}{dt} - \omega_g \cdot \Psi_{sq} \quad (2.3.9)$$

$$v_{sq} = R_s \cdot i_{sq} + \frac{d\Psi_{sq}}{dt} + \omega_g \cdot \Psi_{sd} \quad (2.3.10)$$

$$v_{rd} = R_r \cdot i_{rd} + \frac{d\Psi_{rd}}{dt} - (\omega_g - \omega_r) \cdot \Psi_{rq} \quad (2.3.11)$$

$$v_{rq} = R_r \cdot i_{rq} + \frac{d\Psi_{rq}}{dt} + (\omega_g - \omega_r) \cdot \Psi_{rd} \quad (2.3.12)$$

Las ecuaciones anteriores se pueden expresar de forma matricial, como se muestra en la ecuación (2.3.13):

$$[V] = [R][I] + \frac{d[\Psi]}{dt} + [\omega][\Psi] \quad (2.3.13)$$

En donde:

$$[V] = \begin{bmatrix} v_{sd} \\ v_{sq} \\ v_{rd} \\ v_{rq} \end{bmatrix}$$

$$[\Psi] = \begin{bmatrix} \Psi_{sd} \\ \Psi_{sq} \\ \Psi_{rd} \\ \Psi_{rq} \end{bmatrix}$$

$$[R] = \begin{bmatrix} R_s & 0 & 0 & 0 \\ 0 & R_s & 0 & 0 \\ 0 & 0 & R_r & 0 \\ 0 & 0 & 0 & R_r \end{bmatrix}$$

$$[\omega] = \begin{bmatrix} 0 & -\omega_s & 0 & 0 \\ \omega_s & 0 & 0 & 0 \\ 0 & 0 & 0 & -(\omega_g - \omega_s) \\ 0 & 0 & (\omega_g - \omega_r) & 0 \end{bmatrix}$$

Por otra parte, reemplazando las descomposiciones ortogonales de las corrientes en las expresiones complejas de los flujos, se obtienen las siguientes ecuaciones:

$$\Psi_{sd} + j \cdot \Psi_{sq} = L_s \cdot (i_{sd} + j \cdot i_{sq}) + L_m \cdot (i_{rd} + j \cdot i_{rq}) \quad (2.3.14)$$

$$\Psi_{sd} + j \cdot \Psi_{sq} = L_s \cdot (i_{sd} + j \cdot i_{sq}) + L_m \cdot (i_{rd} + j \cdot i_{rq}) \quad (2.3.15)$$

Igualando las partes reales e imaginarias, tenemos:

$$\Psi_{sd} = L_s \cdot i_{sd} + L_m \cdot i_{rd} \quad (2.3.16)$$

$$\Psi_{sq} = L_s \cdot i_{sq} + L_m \cdot i_{rq} \quad (2.3.17)$$

$$\Psi_{rd} = L_m \cdot i_{sd} + L_r \cdot i_{rd} \quad (2.3.18)$$

$$\Psi_{rq} = L_m \cdot i_{sq} + L_r \cdot i_{rq} \quad (2.3.19)$$

Las ecuaciones anteriores también se pueden escribir de forma matricial:

$$[\Psi] = [L] \cdot [I] \quad (2.3.20)$$

En donde:

$$[I] = \begin{bmatrix} i_{sd} \\ i_{sq} \\ i_{rd} \\ i_{rq} \end{bmatrix}$$

$$[L] = \begin{bmatrix} L_s & 0 & L_m & 0 \\ 0 & L_s & 0 & L_m \\ L_m & 0 & L_r & 0 \\ 0 & L_m & 0 & L_r \end{bmatrix}$$

Se quiere abordar el problema de modelación de la máquina usando las corrientes como variables de estado. Reemplazando (2.3.20) en (2.3.13) se obtiene la representación que se desea:

$$\frac{d[I]}{dt} = [L]^{-1} \cdot [V] - [L]^{-1} \cdot ([R] + [\omega] \cdot [L]) \cdot [I] \quad (2.3.21)$$

En donde:

$$[L]^{-1} = \frac{1}{L_s L_r - L_m^2} \begin{bmatrix} L_r & 0 & -L_m & 0 \\ 0 & L_r & 0 & -L_m \\ -L_m & 0 & L_s & 0 \\ 0 & -L_m & 0 & L_s \end{bmatrix}$$

Para simplificar la notación, se define $D = L_s L_r - L_m^2$, por lo que, finalmente, el modelo con el que se trabajará se presenta en (2.3.22):

$$\frac{d}{dt} [I] = [L]^{-1} [V] + [A] [I] \quad (2.3.22)$$

En donde:

$$[A] = \frac{1}{D} \begin{bmatrix} -L_r R_s & L_r L_s \omega_g - L_m^2 \omega_s & L_m R_r & L_m L_r \omega_r \\ L_m^2 \omega_s - L_r L_s \omega_g & -L_r R_s & -L_m L_r \omega_r & L_m R_r \\ L_m R_s & -L_m L_s \omega_r & -L_s R_r & L_r L_s \omega_s - L_m^2 \omega_g \\ L_m L_s \omega_r & L_m R_s & L_m^2 \omega_g - L_r L_s \omega_s & -L_s R_r \end{bmatrix}$$

$$\omega_s = \omega_g - \omega_r$$

El torque eléctrico está dado por:

$$T_e = \frac{3}{2} p (i_{sq} \cdot i_{rd} - i_{sd} \cdot i_{rq}) \quad (2.3.23)$$

En donde:

p : Número de polos de la máquina.

En la Figura 2.3.3 se muestra un diagrama de bloques con las variables de entrada y salida del modelo del generador.




Figura 2.3.3: Diagrama generador.

El tipo de aerogenerador que se quiere modelar es de rotor bobinado con doble alimentación (doubly-fed induction generator, DFIG). Este tipo de generador tiene adosado a los bornes del rotor un variador de frecuencia (convertor AC/AC) como se muestra en la Figura 2.3.4.

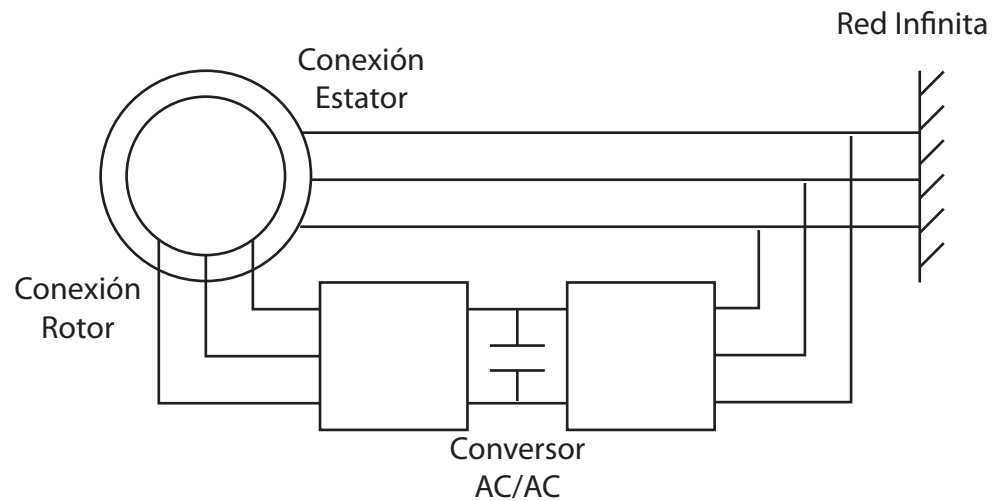


Figura 2.3.4: Esquema de conexión DFIG.

El objetivo de este tipo de conexión es cambiar la velocidad de giro del campo magnético de la máquina eléctrica, mediante la aplicación de un voltaje sinusoidal de frecuencia variable en los terminales del rotor. De esta forma es posible modificar la característica de torque eléctrico versus velocidad de giro de la máquina.

Esta técnica es ideal para aplicarla en aerogeneradores, porque la velocidad de giro de la máquina es incierta; dado que el viento es una variable estocástica. Al disponer de un mecanismo DFIG es posible llevar a la máquina, de manera dinámica, a un punto de operación tal que ésta alcance

una producción máxima de potencia, incluso si la velocidad de giro actual está lejos de alcanzar la velocidad de giro nominal del generador.

El tipo de variador de frecuencia utilizado en esta aplicación consiste en un rectificador trifásico controlado, una etapa de corriente continua y un inversor trifásico controlado.

Tanto el rectificador como el inversor consisten en bancos de tiristores. La etapa continua corresponde a un circuito de corriente continua que cuenta con una inductancia en serie o un condensador en paralelo, que tiene como objetivo eliminar perturbaciones generadas por el proceso de rectificación.

Es necesario modelar el variador de frecuencia para lograr el efecto que se busca en los aerogeneradores DFIG. Una posibilidad es aproximar los arreglos de tiristores por arreglos de interruptores ideales controlados por una fuente PWM [15], sin embargo en [22] y [26] se propone utilizar circuitos RLC aproximados. La razón por la que se prefiere utilizar circuitos aproximados es para simplificar el análisis y simulación del sistema. Para las escalas de tiempo de interés de este problema no se requiere tanta precisión como para tener que modelar los arreglos de tiristores del convertidor [26], por lo que se optó por trabajar con el circuito aproximado.

En la Figura 2.3.5 se muestran los circuitos RLC correspondientes a la aproximación de un variador de frecuencias en el sistema de referencia dq [26]:

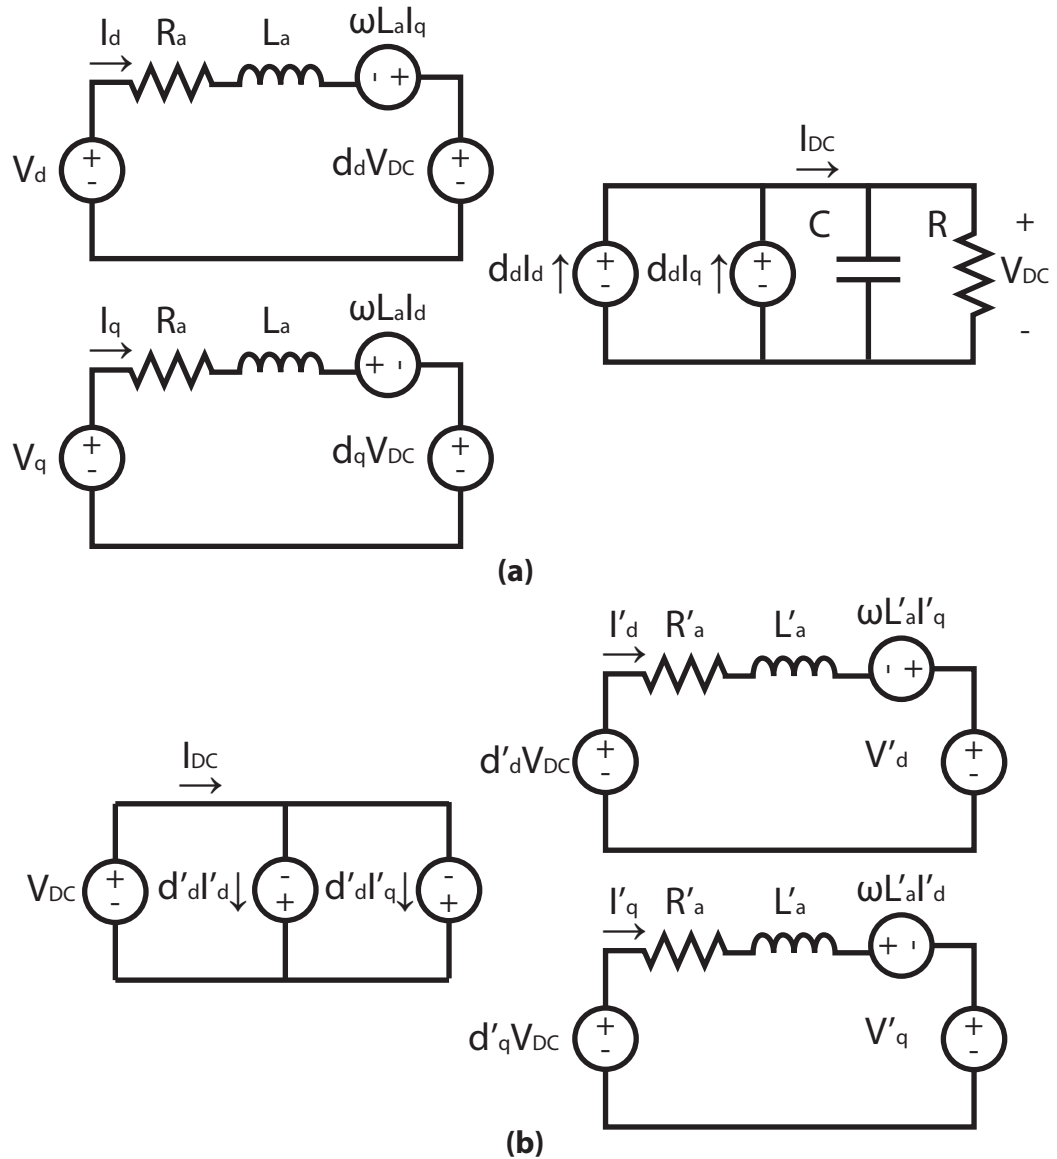


Figura 2.3.5: Circuito RLC aproximado variador de frecuencia.

Los parámetros del circuito presentado en 2.3.5 son:

R_a : Resistencia de línea conectada al rotor.

L_a : Inductancia de línea conectada al rotor.

ω : Velocidad angular de fasor de línea.

V_{DC} : Voltaje continuo obtenido en la etapa de rectificación.

I_d : Corriente en eje directo de rotor.

I_q : Corriente en eje en cuadratura de rotor.

V_d : Voltaje en eje directo de rotor.

V_q : Voltaje en eje en cuadratura de rotor.

d_d, d_q : Ciclos de trabajo del variador de frecuencia.

La operación del convertidor de lado de la red queda descrito por (2.3.24) y (2.3.25):

$$\frac{d}{dt} \begin{bmatrix} I_d \\ I_q \end{bmatrix} = \frac{1}{L_a} \begin{bmatrix} V_d \\ V_q \end{bmatrix} + \begin{bmatrix} -\frac{R_a}{L_a} & \omega \\ -\omega & -\frac{R_a}{L_a} \end{bmatrix} \begin{bmatrix} I_d \\ I_q \end{bmatrix} - \frac{1}{L_a} \begin{bmatrix} d_d \\ d_q \end{bmatrix} V_{DC} \quad (2.3.24)$$

$$\frac{dV_{DC}}{dt} = \frac{1}{C} \begin{bmatrix} d_d & d_q \end{bmatrix} \begin{bmatrix} I_d \\ I_q \end{bmatrix} - \frac{V_{DC}}{RC} \quad (2.3.25)$$

El funcionamiento del convertidor del lado del rotor queda descrito por (2.3.26). Es de forma similar a (2.3.24), sin embargo en este caso el voltaje V_{DC} es una variable independiente.

$$\frac{d}{dt} \begin{bmatrix} I'_d \\ I'_q \end{bmatrix} = \frac{1}{L'_a} \begin{bmatrix} V'_d \\ V'_q \end{bmatrix} + \begin{bmatrix} -\frac{R'_a}{L'_a} & \omega \\ -\omega & -\frac{R'_a}{L'_a} \end{bmatrix} \begin{bmatrix} I'_d \\ I'_q \end{bmatrix} - \frac{1}{L'_a} \begin{bmatrix} d'_d \\ d'_q \end{bmatrix} V_{DC} \quad (2.3.26)$$

En la Figura 2.3.6 se muestra un diagrama de bloques del bloque eléctrico completo. Este bloque consiste en el generador de inducción, el variador de frecuencia conectado a los bornes del rotor y a un modelo de red eléctrica infinita.




Figura 2.3.6: Bloque eléctrico del aerogenerador

2.4. Diagrama de bloques integrado

En la Figura 2.4.1 se muestra el diagrama de bloques de todos los subsistemas integrados. En su conjunto representan el funcionamiento de un aerogenerador DFIG.

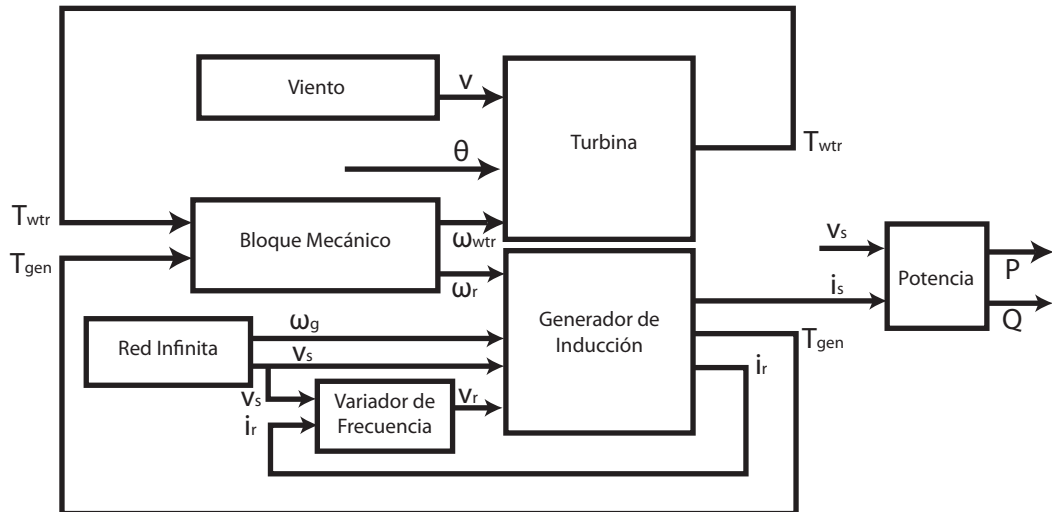


Figura 2.4.1: Diagrama de bloques con los subsistemas del aerogenerador y sus conexiones.

En el siguiente capítulo se presentarán la implementación computacional de los modelos presentados en este capítulo.

Capítulo 3

Implementación de un simulador para un aerogenerador de 2 [MW]

Para la implementación del simulador se tomó como base el simulador desarrollado por Iov, Hansen, Sørensen y Blaabjerg [15]. Dicho simulador fue implementado en MATLAB – Simulink, por lo que todas las mejoras fueron realizadas en la misma plataforma.

El simulador [15] fue desarrollado en bloques. Consiste en una librería que ofrece modelos de una serie de sistemas eléctricos, mecánicos y de viento que, al combinarse entre sí, pueden utilizarse para simular varios sistemas. Dicho simulador no ha sido actualizado últimamente y muchos bloques no coinciden con la documentación asociada al trabajo, por lo que fue necesario revisar exhaustivamente cada uno de los bloques y re-programar algunos para obtener un simulador basado en modelos válidos. En la Figura 3.0.1 se muestra el diagrama de bloques del simulador.

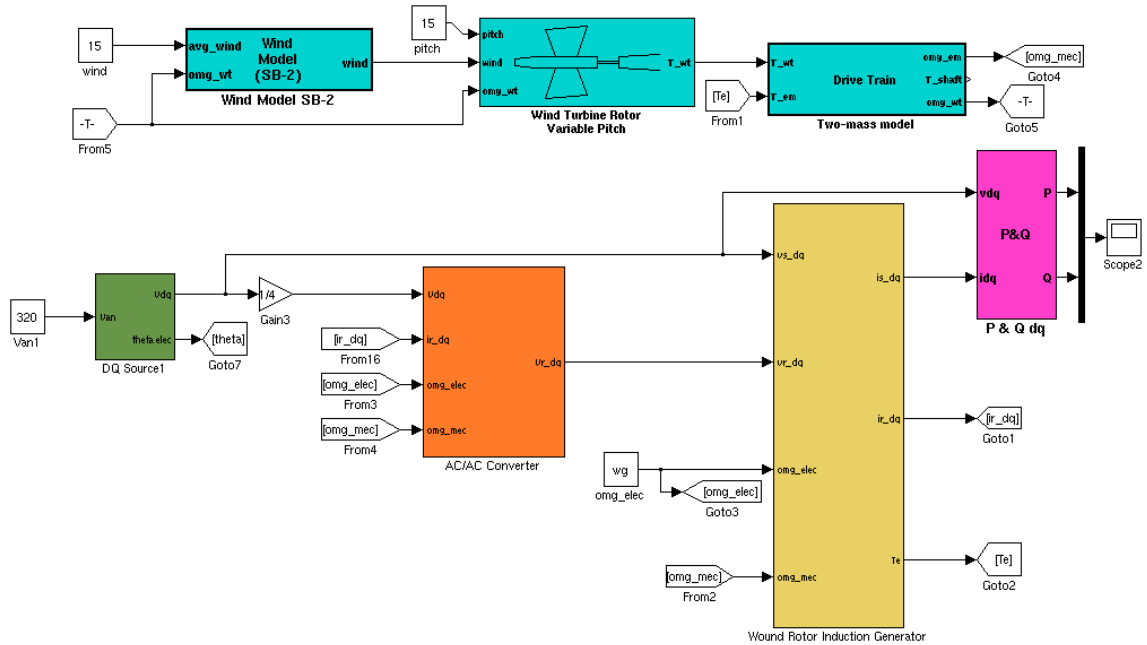


Figura 3.0.1: Diagrama de bloques del simulador de un aerogenerador.

Básicamente se pueden identificar seis bloques principales. El bloque *Wind Model* representa la dinámica del viento, el bloque *Wind Turbine Rotor Variable Pitch* representa la dinámica de la turbina, el bloque *Drive Train* representa el sistema de transmisión mecánico, mientras que el bloque *Wound Rotor Induction Induction Generator* representa al generador de inducción del aerogenerador. Conectado a este último se encuentra el bloque *AC/AC Converter*. Éste corresponde al variador de frecuencia conectado a los bornes del rotor del generador. Los bloques *DQ Source* y *P&Q dq* corresponden a una fuente de voltaje en el sistema dq y a un medidor de potencia activa y reactiva, respectivamente. Cada bloque corresponde a la implementación de los modelos de ecuaciones diferenciales y algebraicas explicados en la sección anterior.

Se revisó la implementación de cada uno de los bloques de la librería [15] necesarios para construir el simulador del aerogenerador. Se pudo observar lo siguiente:

3.1. Bloque viento

Este bloque corresponde a la implementación de un modelo de viento desarrollado en RISØ National Laboratory en Dinamarca [27]. El modelo está basado en el espectro de Kaimal, siendo una componente importante del modelo un generador de ruido blanco. Dicho generador es el que

incorpora la componente aleatoria al sistema, volviéndolo estocástico. El bloque entrega la velocidad del viento promedio sobre toda la turbina. El modelo toma en cuenta la sombra generada por la torre del aerogenerador, así como turbulencias y los efectos generados por la rotación de la turbina.

Los parámetros del bloque son el diámetro de la turbina, la velocidad promedio del viento, la escala de longitud, la intensidad de la turbulencia y el tiempo de muestreo.

En este trabajo no se abordará mayormente el problema de modelación y simulación de viento, por lo que este bloque se utilizó sin mayores modificaciones, salvo ajustes en los parámetros de ciertas componentes que no permitían que el bloque funcionara correctamente.

Los parámetros utilizados para modelar el viento necesario para mover la turbina de un aerogenerador de 2 MW fueron los siguientes:

- Diámetro de la turbina: 87 m
- Velocidad promedio del viento: $4 \text{ m/s} - 18 \text{ m/s}$
- Escala de longitud: 600 m
- Intensidad de la turbulencia: 12 %
- Tiempo de muestreo: 0.001 s

3.2. Bloque aerodinámico

El bloque correspondiente a la turbina debe simular los cuatro modos de operación de la turbina:

1. Cuando la velocidad del viento es menor que el umbral mínimo de funcionamiento, la potencia generada es cero.
2. Cuando la velocidad del viento es mayor que el umbral de funcionamiento y menor que la velocidad nominal de viento, la potencia generada queda determinada por (3.2.1).
3. Cuando la velocidad del viento sobrepasa la velocidad de viento nominal, comienza a actuar el limitador de potencia. De esta forma, para velocidades de viento por sobre la nominal, el aerogenerador entregará potencia nominal.

4. Cuando la velocidad del viento sobrepasa el umbral máximo de funcionamiento, se detiene completamente la turbina para protegerla de daños. En este estado la potencia generada es cero.

La ecuación de torque es la siguiente:

$$T_{wt} = \frac{1}{2} \pi \rho R^3 v^2 C_T(\lambda, \theta) \quad (3.2.1)$$

En la Figura 3.2.1 se muestra la implementación del bloque de la turbina. El bloque *switch* presente en el modelo es el bloque que genera las transiciones entre un estado de operación y otro, teniendo como base condiciones establecidas sobre la velocidad presente del viento.

En la misma figura, se pueden identificar bloques que calculan el valor λ a partir de la velocidad del viento y la velocidad de giro de la turbina, así como un bloque que incorpora cierto retardo en el actuador de cambio de ángulo de ataque. Ambos bloques se utilizan para alimentar el bloque C_T , para luego calcular el torque generado por la turbina utilizando (3.2.1).

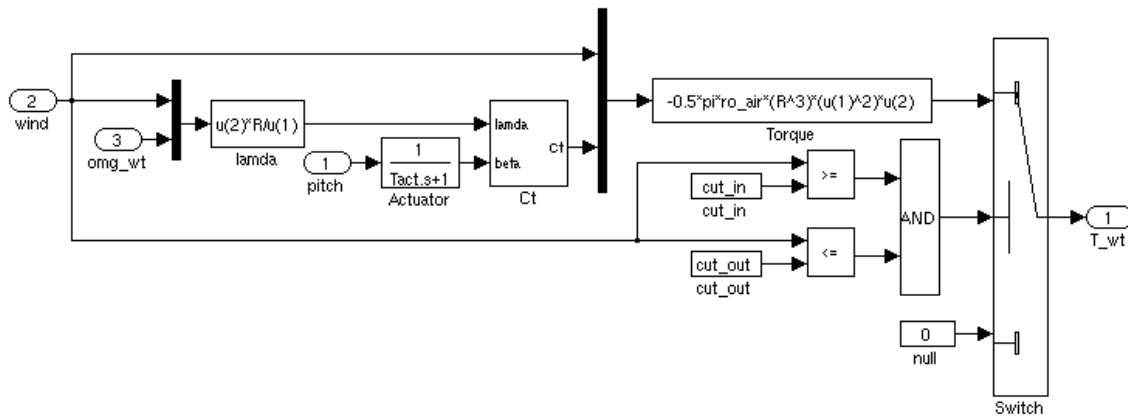


Figura 3.2.1: Implementación del bloque de la turbina.

En el simulador original el cálculo del coeficiente C_T se realizaba a través de un look-up table. Esta técnica consiste en utilizar una tabla de doble entrada para obtener un valor de salida que ha sido tabulado previamente. La tabla contiene valores discretos, por lo que si se requiere conocer el valor C_T para cantidades que no están incorporadas a la tabla, el bloque automáticamente interpola los valores que faltan. Vale la pena recordar que el coeficiente de torque C_T es una función no-lineal de λ y θ . C_T es una de las características más relevantes en la caracterización de una turbina en particular.

La versión disponible del simulador [15] presenta problemas de funcionamiento en la look-up table. El simulador incluye un archivo de texto con los datos que describen el coeficiente de torque C_T de una turbina en particular para valores de λ que oscilan entre 0 y 20, y para valores de ϑ que oscilan entre -90° y 90° . La idea es volcar dichos valores al bloque de MATLAB – Simulink look-up table para poder acceder al valores de C_T asociados a cierto par (λ, θ) de forma dinámica y eficiente durante la simulación. El principal problema que presenta el bloque recién mencionado es que para ciertos pares (λ, θ) , contenidos en el subconjunto formado por los rangos de operación válidos de cada variable, no existe un valor válido de C_T . De esta forma, si se accede a alguno de dichos valores, en el siguiente paso se intentará operar con un valor inválido, lo que arrojará un error y se detendrá la simulación. Otro problema se presenta cada vez que se ingresa un valor fuera de rango a la tabla. En esta situación, el bloque arroja una excepción que detiene la simulación.

El primer problema se puede solucionar “reparando” la tabla de datos que modela el coeficiente C_T . Para eso se tomó el conjunto de datos original utilizado por el simulador [15] y se interpolaron los datos erróneos para, finalmente, obtener una matriz C_T con valores válidos en todo el rango de operación. En la Figura 3.2.2 se muestra tanto la versión original de la función C_T , como la versión reparada. En la versión original se pueden apreciar las discontinuidades que afectaban el funcionamiento de la simulación.




Figura 3.2.2: Función C_T sin reparar y posteriormente reparada.

A pesar que el simulador comenzó a funcionar correctamente después de la reparación de la tabla de datos, se optó por dejar de trabajar con look-up tables y se reemplazó por una función C_T encontrada en la literatura para darle mayor validez al modelo [25].

En (3.2.2) se muestra el coeficiente de torque utilizado:

$$C_T(\lambda, \theta) = 0,22 \left(\frac{116}{\lambda_i} - 0,4\theta - 5 \right) e^{\frac{-12,5}{\lambda_i}} \quad (3.2.2)$$

En donde λ_i depende de la razón entre la velocidad en las puntas de las palas y la velocidad del viento y de el ángulo de ataque de las palas, como se muestra en (3.2.3):

$$\frac{1}{\lambda_i} = \frac{1}{\lambda + 0,08\theta} - \frac{0,035}{\theta^3 + 1} \quad (3.2.3)$$

En la Figura 3.2.3 se muestra el gráfico de (3.2.2):

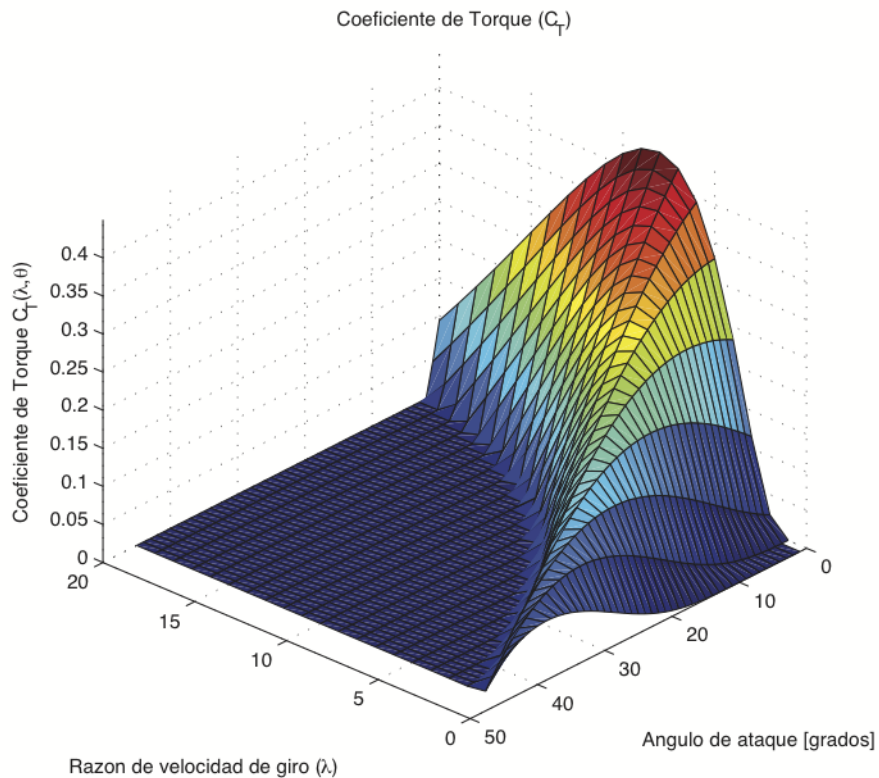


Figura 3.2.3: Coeficiente de torque.

El segundo problema está directamente relacionado con las acciones de control que se aplicarán sobre la turbina. Particularmente se debe tener cuidado en que el ángulo de ataque de la turbina en todo momento se encuentre en el rango entre 0° y 45° , para que la variable se mueva sólo en el rango de operación factible de una turbina. La solución a este problema se abordó más tarde, al momento de diseñar una estrategia de control básica para el sistema, por lo que la explicación de ese punto se realiza en dicha sección.

No se modificaron las demás componentes de la estructura de este bloque.

Los parámetros utilizados para la turbina que forma parte del aerogenerador de 2 MW que se quiere simular son los siguientes:

- Radio turbina: 43.5 m
- Densidad del aire: 1.25 Kg/m^3
- Velocidad de entrada en operación: 3 m/s
- Velocidad de salida de operación: 20 m/s
- Constante de tiempo actuador: 5 s

3.3. Bloque mecánico

El bloque mecánico implementado en el simulador [15] corresponde a una simplificación de segundo orden del modelo mecánico basado en ecuaciones diferenciales presentado anteriormente. Este bloque no presentó problemas de funcionamiento, por lo que no fue modificado de ninguna forma. En la Figura 3.3.1 se muestra la implementación de dicho bloque en MATLAB – Simulink.

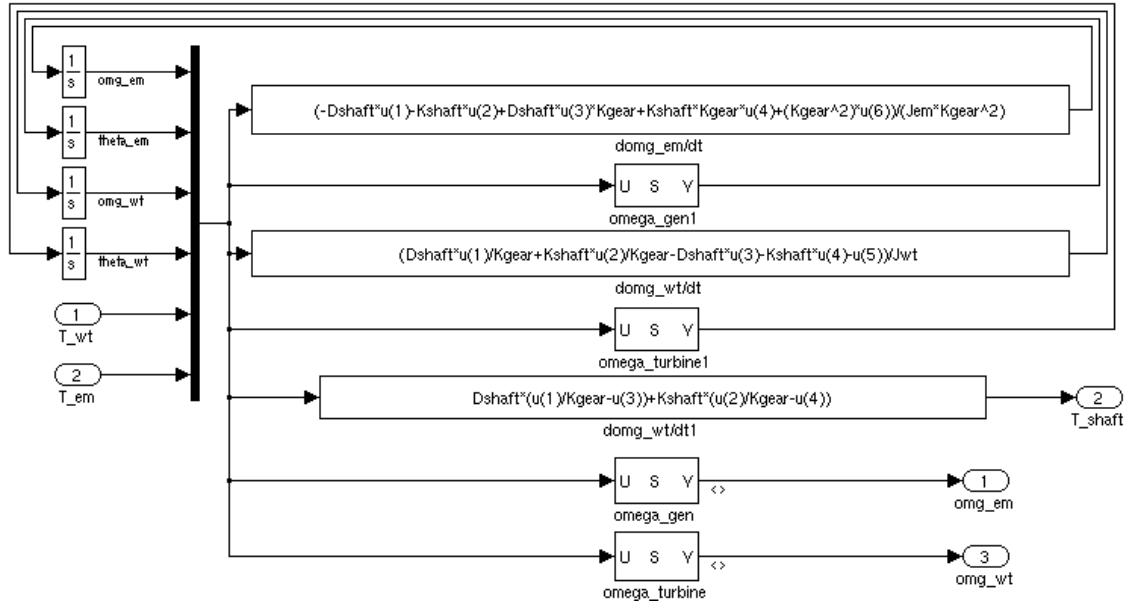


Figura 3.3.1: Implementación bloque mecánico.

Los parámetros utilizados para el sistema mecánico que forma parte del aerogenerador de 2 [MW] que se quiere simular son los siguientes:

- J_{em} : Momento de inercia máquina eléctrica: 90 Kg/m²
- J_{wt} : Momento de inercia turbina eólica: 49.5·10⁵ Kg·m²
- k_{shaft} : Coeficiente de rigidez del eje: 755.658 Nm
- k_{gear} : Razón de transformación engranes: 77.925
- ω_{mo} : Velocidad inicial de giro del eje: 157.08 rad/s
- ω_{wto} : Velocidad inicial de giro de la turbina: 2.01578 rad/s

3.4. Bloque eléctrico

El bloque eléctrico fue totalmente reprogramado. Se programó el modelo en variables de estado de la máquina de inducción correspondiente a (2.3.22), además del sistema variador de frecuencia para realizar la doble alimentación.

3.4.1. Máquina de inducción

En la Figura 3.4.1 se muestra la implementación de un simulador de la ecuación de estado de una máquina de inducción de rotor bobinado. La ecuación de estado corresponde a (2.3.22). También se incorporó al simulador una implementación de (2.3.23), correspondiente a la función de torque eléctrico de la máquina de inducción. El torque eléctrico es fundamental para realizar el acople de las ecuaciones de la máquina de inducción con las del sistema mecánico.

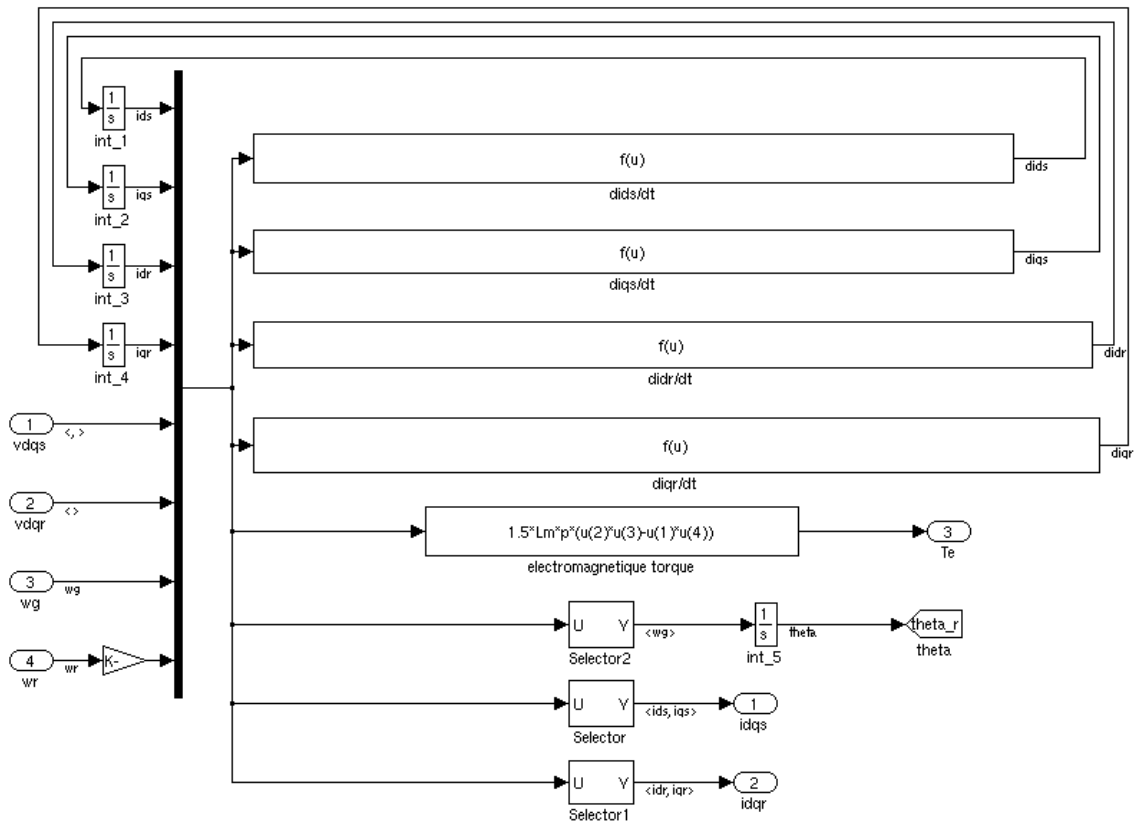


Figura 3.4.1: Implementación modelo máquina de inducción.

Los parámetros utilizados para la máquina de inducción que forma parte del aerogenerador de 2 [MW] que se quiere simular son los siguientes:

- $w_g = 2 \cdot 50 \cdot \pi$
- $p = 4$
- $R_s = 0.01 [\Omega]$

- $R_r = 0.01[\Omega]$
- $L_m = 0.0955[H]$
- $L_s = 0.095596[H]$
- $L_r = 0.095596[H]$

3.4.2. Variador de frecuencia

En las Figuras 3.4.2, 3.4.3, 3.4.4 y 3.4.5 se muestra la implementación de un simulador basado en las ecuaciones que describen el funcionamiento de un variador de frecuencia para excitar el rotor de la máquina de inducción del aerogenerador de 2 [MW]. El simulador está basado en las Ecuaciones (2.3.24), (2.3.25) y (2.3.26).

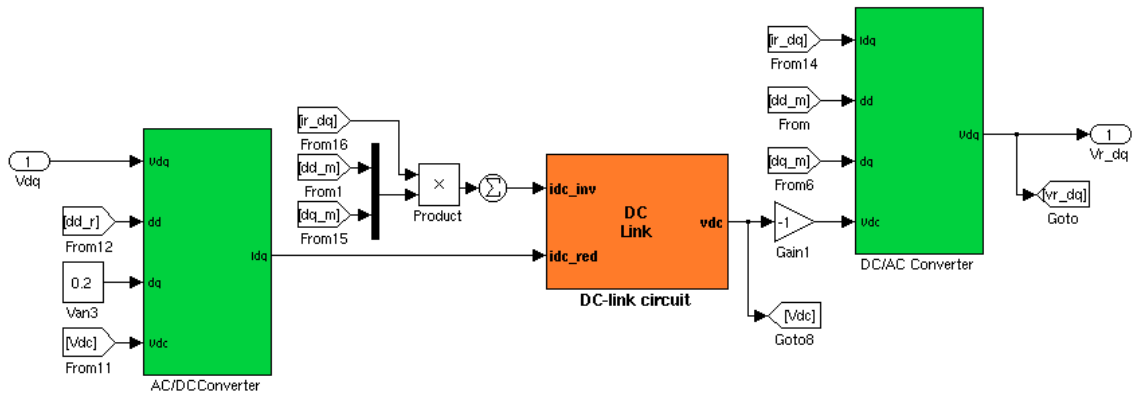


Figura 3.4.2: Conversor AC/AC completo.

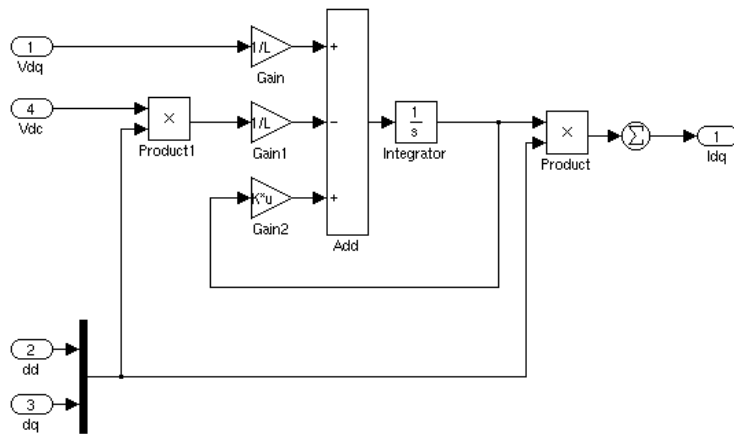


Figura 3.4.3: Conversor AC/DC.

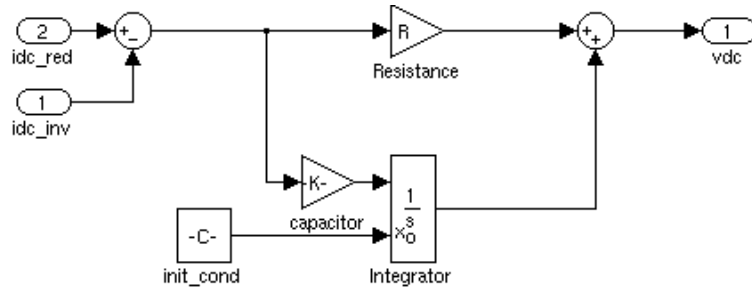


Figura 3.4.4: DC Link.

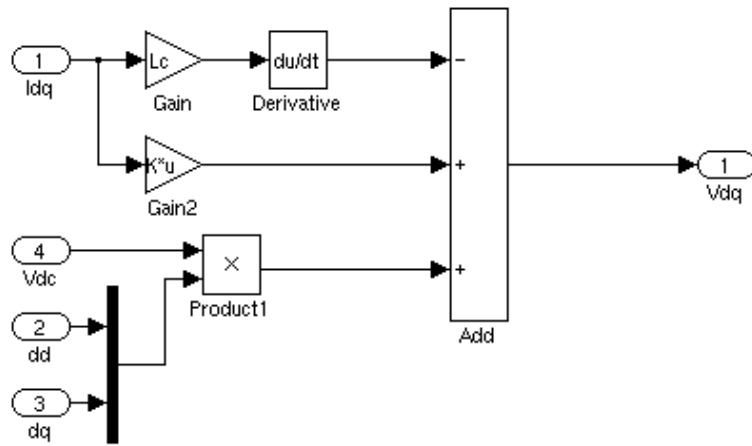


Figura 3.4.5

Los parámetros utilizados para el variador de frecuencia son los siguientes:

- $L_a = 0.00012[H]$
- $R_a = 0.01[\Omega]$
- $L'_a = 0.00006[H]$
- $R'_a = 0.03[\Omega]$
- $R = 0.001[\Omega]$
- $C = 1200[\mu F]$

3.5. Implementación de estrategias de control

El sistema requiere de cuatro lazos de control. El primero consiste en control de velocidad de giro del rotor, mientras que los restantes están orientados al control del variador de frecuencia.

En todos los casos se optó por estrategias de control PI o PID. Los parámetros se obtuvieron mediante la técnica de curva de reacción de Zyegler – Nichols.

Típicamente, en un aerogenerador, las variables manipuladas son las siguientes:

- Ángulo de ataque de las palas (θ)
- Voltaje de eje directo de rotor (v_{rd})
- Voltaje de eje en cuadratura de rotor (v_{rq})

Las variables controladas son las siguientes:

- Potencia activa (P)
- Potencia reactiva (Q)

Las perturbaciones del sistema son las siguientes:

- Velocidad del viento (v)
- Voltaje de estator (v_s)

Se deben construir lazos de control independientes para controlar las potencias activa y reactiva. La potencia activa P se controla variando el ángulo de ataque de las palas θ , mientras que la potencia reactiva se controla manipulando el voltaje aplicado en bornes del rotor v_r .

En las Figuras 3.5.1 y 3.5.2 se muestran las características de potencia y torque de la máquina de inducción, respectivamente.

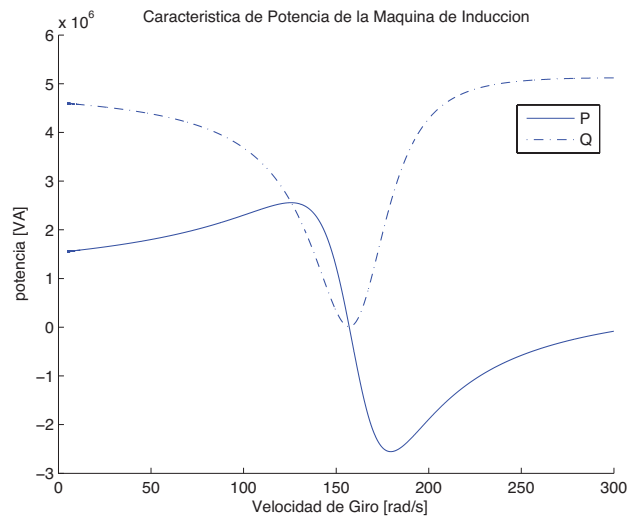


Figura 3.5.1: Característica de potencia de la máquina de inducción.

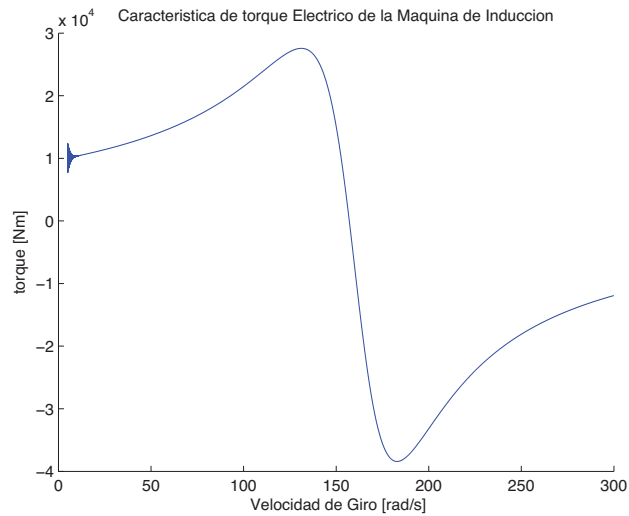


Figura 3.5.2: Característica de torque de la máquina de inducción.

En la Figura 3.5.1 se puede observar que la máquina opera como generador cuando la velocidad de giro del rotor supera la mitad de la velocidad síncrona del sistema. Esto se debe a que la máquina posee cuatro polos. La velocidad síncrona del sistema corresponde a $2 \cdot 50 \cdot \pi [\text{rad/s}]$.

3.5.1. Control de velocidad de giro de la turbina

Se esperaría que la máquina opere constantemente a una velocidad en torno a los 160 [rad/s], que es la velocidad a la que se alcanza una producción de potencia activa de 2 [MW]. Con ese objetivo se diseñó un controlador PI, cuya variable controlada es la velocidad de giro del rotor (ω_r) y la variable manipulada es el ángulo de ataque (θ) de las palas de la turbina.




Figura 3.5.3: Controlador PID velocidad de giro de la turbina.

Como se dijo anteriormente, el ángulo de ataque de las palas tiene un funcionamiento acotado entre 0° y 45° . Para evitar la saturación del actuador, se incorporó una estrategia de antiwindup, como puede verse en la Figura 3.5.3.

En la Tabla 3.5.1 se muestran los parámetros considerados para el controlador. El tiempo de estabilización del sistema es de aproximadamente 5 [s], con una sobreoscilación del 10 %

Cuadro 3.5.1: Parámetros controlador PI - Velocidad de giro

Parámetro	Valor
K_p	3
K_I	1

3.5.2. Control del variador de frecuencia

A continuación se muestra el controlador del variador de frecuencia. El diseño del controlador está basado en la estrategia propuesta en [26]. Además se incorporó antiwindup en todos los lazos de control para evitar saturación del actuador.

En la Figura 3.5.4 se muestra el lazo de control del voltaje V_{rd} . La variable controlada es V_{rd} y la variable manipulada es índice de modulación d_d del controlador PWM que controla el arreglo de tiristores del lado del rotor.

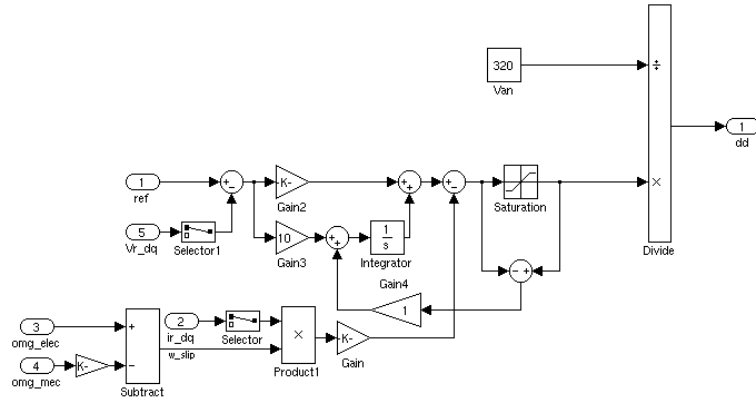


Figura 3.5.4: Controlador V_{rd} .

En la Tabla 3.5.2 se muestran los parámetros considerados para el controlador.

Cuadro 3.5.2: Parámetros controlador PI - V_{rd}

Parámetro	Valor
P	100
I	10

En la Figura 3.5.5 se muestra el lazo de control del voltaje V_{rq} . La variable controlada es V_{rq} y la variable manipulada es índice de modulación d_q del controlador PWM que controla el arreglo de tiristores del lado del rotor.

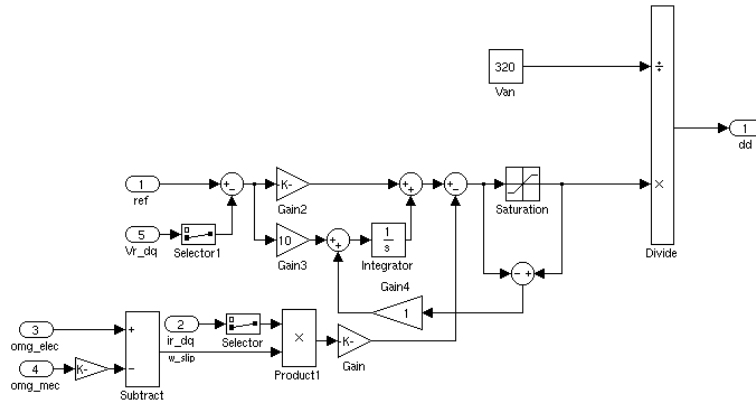


Figura 3.5.5: Controlador V_{rq} .

En la Tabla 3.5.3 se muestran los parámetros considerados para el controlador.

Cuadro 3.5.3: Parámetros controlador PI - V_{rq}

Parámetro	Valor
K_P	100
K_I	10

Es necesario que la etapa de corriente continua permanezca a voltaje V_{dc} constante en todo momento, a pesar de las perturbaciones. Por eso la etapa de corriente continua también requiere de un controlador. La variable controlada corresponde a V_{dc} , mientras que la variable manipulada corresponde al índice de modulación d_d del controlador PWM que controla el arreglo de tiristores del lado del estator.




Figura 3.5.6: Controlador V_{dc} .

En la Tabla 3.5.4 se muestran los parámetros considerados para el controlador.

Cuadro 3.5.4: Parámetros controlador PI - V_{dc}

Parámetro	Valor
K_P	0.001
K_I	0.0001

3.6. Discusión

En este capítulo se explicitó la forma en que se implementó el simulador del aerogenerador de 2 [MW]. El simulador consiste en cuatro bloques principales interconectados entre sí. El bloque viento consiste en un generador de números aleatorios que siguen una distribución similar a la del viento. El bloque aerodinámico representa a la turbina del aerogenerador. El bloque mecánico representa la caja multiplicadora de engranajes que une la turbina con el generador de inducción. El bloque eléctrico representa al generador y al variador de frecuencias.

Todo el sistema está gobernado por cuatro lazos de control. Las estrategias de control consisten

en controladores proporcional-integral (PI), que es suficiente para los objetivos de este trabajo.

Como se mostrará en el siguiente capítulo, el generador será utilizado para tomar datos de entrada y salida, los que se usarán como caso de prueba de un nuevo método de identificación difusa basado en inteligencia computacional.

Capítulo 4

Método de identificación de modelos difusos

Una vez que se tiene construido el simulador de un aerogenerador, se procederá a realizar identificación difusa de éste a partir de mediciones obtenidas a través del simulador. En este trabajo se presenta un nuevo método de identificación difusa basado en algoritmos genéticos (genetic algorithms, GA) y optimización por enjambre de partículas (particle swarm optimization, PSO).

En ciertos problemas de optimización de alta complejidad se debe recurrir a métodos que puedan resolverlos de manera eficiente, aceptando en ocasiones que la solución no sea la óptima, si no que sea sólo cercana a ésta. En este contexto, los algoritmos inteligentes de optimización basados en poblaciones resultan ser muy adecuados [19].

Los algoritmos evolutivos son la familia más grande y reconocida de algoritmos de optimización basados en poblaciones [4]. Bajo esta categoría se incluyen las subfamilias de algoritmos genéticos, programación evolutiva, estrategias evolutivas y programación genética.

Por otra parte, la optimización por enjambre de partículas [7] es un algoritmo perteneciente a la familia de inteligencia de enjambres. Si bien esta rama se desarrolla de forma independiente de la familia de los algoritmos evolutivos, diversos estudios han encontrado similitudes entre la optimización por enjambre de partículas y otros algoritmos evolutivos, como los algoritmos genéticos y la programación evolutiva [17].

A continuación se muestra una breve descripción de GA y PSO, necesaria para la posterior

presentación del nuevo método de identificación difusa.

4.1. Algoritmos genéticos

Los algoritmos evolutivos (evolutionary algorithms, EA) son métodos iterativos de optimización estocástica inspirados en conceptos de la teoría evolutiva de Darwin. En la teoría de Darwin, a medida que transcurren las generaciones, la población de una especie evoluciona de tal forma que aquellos miembros que logran adaptarse de mejor forma al entorno tienen mayor probabilidad de sobrevivir y de reproducirse. Dichas características que permitieron la mejor adaptación del individuo son heredadas por su descendencia, por lo que los mejores rasgos tienden a permanecer en la población por otras generaciones y los peores tienden a desaparecer.

Un algoritmo evolutivo simula el proceso de evolución en una población de individuos. Se propone una población inicial de soluciones candidatas para el problema de optimización y se generan nuevos individuos a partir de los originales. En cada generación sobreviven con mayor probabilidad aquellos individuos que presenten soluciones más cercanas a la óptima, por lo que la población tiende a evolucionar hacia la mejor solución aproximada del problema de optimización en cuestión. En el ciclo de simulación, tres operaciones se encuentran en juego: selección, recombinación y mutación. Los operadores de recombinación y mutación crean nuevas soluciones candidatas, mientras que la selección descarta los individuos de baja calidad, la que es evaluada por *fitness* o adaptación. Valores de *fitness* más altos o más bajos, dependiendo si es un problema de maximización o minimización, indican mejor calidad de las soluciones [19].

Los algoritmos genéticos son los principales representantes de la familia de los algoritmos evolutivos. Una primera versión de GA fue presentada por John Holland [14]. Sus principales características son el fuerte énfasis en el operador de recombinación, el uso de un operador de selección probabilística (selección proporcional) y la interpretación de la mutación como un operador de apoyo a la recombinación. Además la forma original de los algoritmos genéticos se basa en el uso de codificación binaria, sin embargo esta ha sido adaptada para incluir codificaciones reales para aplicarlo de un modo más directo a espacios de búsqueda que no son binarios.

Conceptualmente, un EA mantiene una población de individuos que son seleccionados y creados en un proceso iterativo. Un individuo consiste en un cromosoma, un *fitness* y un número de variables auxiliares que permiten controlar el proceso evolutivo. El cromosoma consiste en el número de genes

que en su conjunto codifican una solución del problema de optimización. El *fitness* representa la calidad de la solución codificada en el cromosoma del individuo, que usualmente corresponde a la función objetivo del problema de optimización o de una función monótonamente creciente con respecto a la función objetivo cuando se trata de problemas de maximización. Cuando se trata de problemas de minimización, las soluciones de mejor calidad son las que presentan valores menores de la función objetivo; por lo que en dichos casos el *fitness* usualmente es una función monótonamente decreciente respecto de la función objetivo.

Todos los EA's tienen una fase de inicialización seguida de una fase iterativa, en donde la población inicial evoluciona hacia mejores soluciones del problema. En el Algoritmo 4.1 se muestra el pseudo-código de un algoritmo evolutivo tipo.

Algoritmo 4.1 Algoritmo evolutivo estándar.

01. $k = 0$. Inicializar Población $P(0)$
 02. Evaluar Población $P(0)$
 03. Mientras no se cumpla condición de término
 04. $k = k + 1$
 05. Seleccionar población $P'(k)$ a partir de $P(k-1)$.
 06. Crear población $P(k)$ a partir de $P'(k)$.
 07. Evaluar Población $P(k)$.
 08. Finalizar
 09. Solución del problema es el mejor elemento de $P(k)$.
-

4.1.1. Terminología básica

A la estructura de los individuos (soluciones candidatas) se les conoce como cromosomas. Este es el genotipo manipulado por el GA. Normalmente el genotipo de un individuo corresponde a la codificación binaria de una solución candidata de la función objetivo. Así como a la solución codificada en binario se le conoce como genotipo, a la solución decodificada, perteneciente al espacio de la función objetivo, se le conoce como fenotipo. Al valor de cada bit en un cromosoma se le conoce como gen; sin embargo, cuando un conjunto de bits representa un único parámetro en el espacio fenotípico, se suele denominar gen a dicho conjunto. En la Figura 4.1.1 se presenta una solución candidata para un problema de optimización codificada en un cromosoma. El problema de optimización posee dos variables, cada una codificada con una precisión de 8 bits, identificadas como “Gen 1” y “Gen 2”.




Figura 4.1.1: Ejemplo de cromosoma

4.1.2. Codificación

Los parámetros en EA's tradicionalmente se representan con codificación binaria. La estructura de datos utilizada es un vector de bits con largo fijo L , que corresponde a 2^L soluciones distintas en el espacio de búsqueda.

Se debe especificar la función decodificadora que mapea la representación binaria de un cromosoma en un número de punto flotante. La función decodificadora convierte un número binario en un número decimal que será utilizado para evaluar la función de fitness. Si un cromosoma está codificado en L bits, el valor correspondiente en representación punto flotante x_{real} está dado por (4.1.1).

$$x_{real} = x_{min} + \frac{x_{max} - x_{min}}{2^L - 1} \left(\sum_{i=0}^{L-1} x[i] \cdot 2^{L-1-i} \right) \quad (4.1.1)$$

En donde x_{min} y x_{max} son los valores mínimos y máximos que puede tomar x y $x[i]$ es el i -ésimo bit del gen en codificación binaria.

4.1.3. Mutación

El procedimiento de mutación más común para problemas de codificación binaria es aquel conocido como bit-flip. Este procedimiento consiste en una iteración sobre todos los genes del cromosoma, en donde el gen i será cambiado con una probabilidad p_m . Esto se logra asignando un número aleatorio $r_i \in U(0, 1)$ a cada bit i . Si el número obtenido r_i es menor que p_m , entonces el bit i es cambiado.

El principal problema de este operador es que es de orden $O(L)$ para cromosomas de largo L , de modo que la implementación directa es ineficiente. Existen técnicas que mejoran el desempeño del procedimiento de mutación, pero no serán presentadas en este trabajo.

4.1.4. Crossover

Un operador ampliamente utilizado para la codificación binaria es el crossover de n puntos. Éste recombina los genes de dos o más padres para crear cromosomas de dos descendientes.

En el crossover de un punto, los cromosomas de los padres, de tamaño n , son cortados y reensamblados en una posición aleatoria p del cromosoma. El primer descendiente (*offspring*) recibe los genes entre $\text{gen}[1]$ y $\text{gen}[p-1]$ del padre #1 y el resto de los genes, es decir del $\text{gen}[p]$ al $\text{gen}[n]$, del padre #2. El cromosoma del segundo descendiente es ensamblado a partir de los genes restantes de cada padre. Es decir, los genes comprendidos entre el $\text{gen}[1]$ y el $\text{gen}[p-1]$ provienen del padre #2, mientras que los genes entre el $\text{gen}[p]$ y el $\text{gen}[n]$ provienen del padre #1.

El crossover se aplica con una probabilidad p_c para cada par de padres. Si no se ejecuta, los descendientes son copias idénticas de los padres.

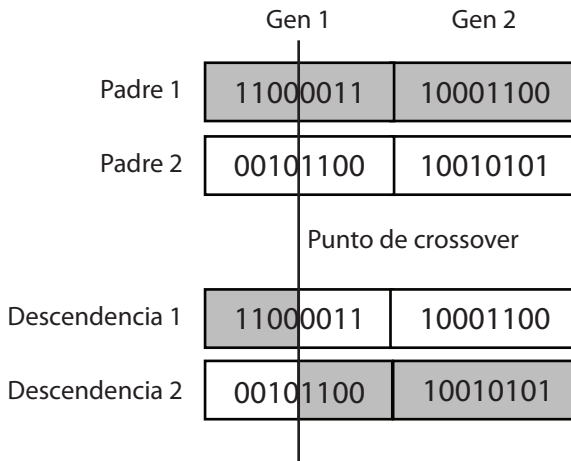


Figura 4.1.2: Crossover de un punto.

La diferencia entre crossover de 1 punto y el crossover de n puntos está en el uso de n puntos de corte en vez de uno. Entre cada punto de crossover se alterna el origen de los genes de la descendencia. Se utiliza un valor de n entre 1 y 4.

4.1.5. Operadores de selección

El operador de selección remueve individuos con un *fitness* bajo y lleva a la población a estar formada por individuos de mejor calidad. En definitiva, este operador actualiza la población de una iteración a la siguiente.

En general, el operador de selección puede reemplazar a la población completa o sólo a una parte de ésta.

4.1.6. Descripción general de los algoritmos genéticos

En los algoritmos genéticos se utiliza recombinación como el operador de búsqueda más importante y se aplica mutación con una probabilidad muy pequeña tan sólo como un operador adicional. El objetivo de aplicar mutación es mantener diversidad en la población, de tal forma de explorar áreas inexploradas del espacio de soluciones factible y así evitar la convergencia del algoritmo en óptimos locales.

El GA básico comienza con una población inicial $P(0)$ que generalmente es inicializada al azar. Se evalúa el fitness de cada individuo. Luego, algunos de estos individuos son seleccionados para reproducirse y pasan a un conjunto $C(k)$. A este conjunto se le aplican operadores de crossover y mutación obteniendo una población $C'(k)$. En general, la nueva población $P(k+1)$ es construida sólo con la descendencia $C'(k)$ si esta es del mismo tamaño que la población inicial, aunque existen ciertos enfoques en que se seleccionan también los mejores padres y se elimina la peor parte de la descendencia para formar la población de la siguiente iteración. En el Algoritmo 4.2 se presenta el pseudo-código de un algoritmo genético estándar.

Algoritmo 4.2 Algoritmo genético estándar.

01. $k = 0$. Inicializar Población $P(0)$
 02. Evaluar Población $P(0)$
 03. Mientras no se cumpla condición de término
 04. $k = k + 1$
 05. Seleccionar población $C(k)$ a partir de $P(k-1)$.
 06. Crear población $C'(k)$ a partir de $C(k)$ utilizando operadores de crossover y mutación.
 07. Construir población $P(k)$ a partir de descendencia $C'(k)$ y completar en caso de ser necesario con población de padres $P(k-1)$.
 08. Evaluar Población $P(k)$.
 09. Finalizar
 10. Solución del problema es el mejor elemento de $P(k)$.
-

4.2. Optimización por enjambre de partículas

La optimización por enjambre de partículas es un algoritmo de optimización basado en poblaciones. Se inspira en el comportamiento de bandadas de aves, cardúmenes, enjambres de abejas e incluso en el comportamiento social humano [17]. PSO es una herramienta de optimización basada en poblaciones que puede ser aplicada de un modo sencillo para resolver diferentes problemas de optimización. Las principales fortalezas de PSO son su rápida convergencia en relación a otros algoritmos de optimización, como GA [12] o temple simulado (Simulated Annealing, SA) [21]. De acuerdo a algunos estudios [1, 8], es posible afirmar que el comportamiento de PSO puede catalogarse como el de un algoritmo evolutivo, en algún lugar entre algoritmos genéticos y programación evolutiva.

Para aplicar PSO satisfactoriamente, uno de los puntos clave es encontrar como mapear la solución del problema en la partícula de PSO, lo que afecta directamente su factibilidad y desempeño.

De un modo similar a los algoritmos evolutivos, PSO utiliza un mecanismo de búsqueda basado en poblaciones. Los individuos son conocidos como partículas en la literatura PSO. Éstas tienden a seguir a la partícula más fuerte, que es aquella que proporciona la mejor solución candidata hasta la iteración en que se encuentra el algoritmo. Además de seguir la tendencia de la mejor solución candidata global del problema, cada partícula toma en cuenta su historia personal, por lo que también tiende a permanecer cerca de la mejor solución candidata encontrada por ella misma.

4.2.1. Modelo canónico de optimización por enjambre de partículas

De acuerdo a [19], el modelo canónico PSO consiste en un enjambre de partículas. Cada partícula representa una solución candidata al problema de optimización, por lo que el enjambre de partículas es un conjunto de soluciones candidatas al problema de optimización. Las partículas, cada una de dimensión d , se mueven iterativamente por el espacio de soluciones factibles del problema. En cada iteración, las partículas exploran el espacio de soluciones factibles para buscar nuevas y mejores soluciones al problema. La exploración se realiza guiada por el *fitness* f de cada partícula, que es una medida de calidad de la solución. En la mayor parte de los problemas de optimización, conviene que la función de *fitness* sea la misma función objetivo por optimizar. Cada partícula i tiene una posición instantánea, representada por un vector x_i . Éste representa la solución candidata al problema de optimización. Cada partícula además tiene una velocidad instantánea, representada

por el vector v_i . Las coordenadas j de los vectores de posición y velocidad son respectivamente x_{ij} y v_{ij} . Cada partícula recuerda su mejor posición en la historia de su búsqueda en el vector $pbest_i$ (*particle best*) y, además, cada partícula conoce la mejor posición alcanzada por cualquier partícula en la historia de la búsqueda. Ésta se guarda en el vector $gbest$ (*global best*). En la iteración $k + 1$, se actualiza la velocidad de cada partícula de acuerdo a la velocidad previa. Además se actualizan los valores de $pbest_i$ y de $gbest$, en caso que alguna partícula haya alcanzando su mejor solución histórica propia o la mejor solución histórica del problema completo. Luego, la nueva posición se calcula como la suma de la posición previa con la nueva velocidad, tal como se muestra en (4.2.1).

$$\begin{aligned} v_{ij}(k+1) &= \omega \cdot v_{ij}(k) + c_1 \cdot \phi_1 \cdot (pbest_i(k) - x_{ij}(k)) + c_2 \cdot \phi_2 (gbest(k) - x_{ij}(k)) \\ x_{ij}(k+1) &= x_{ij}(k) + v_{ij}(k+1) \end{aligned} \quad (4.2.1)$$

En (4.2.1), ω es el factor de inercia, c_1 es la constante cognitiva y c_2 es la constante social de las partículas. Tanto ω como c_1 y c_2 son parámetros de sensibilidad del algoritmo. El comportamiento cognitivo representa la tendencia de cada partícula a dirigirse hacia su mejor posición histórica conocida $pbest_i$. El comportamiento social representa la tendencia de las partículas a dirigirse hacia la mejor posición conocida entre todos los miembros del enjambre $gbest$. ϕ_1 y ϕ_2 son números aleatorios uniformemente distribuidos entre 0 y 1. La presencia de ambos números en la fórmula permite mantener diversidad en el enjambre. Por lo tanto, la nueva velocidad depende de un factor de inercia y, además, de correcciones provenientes del comportamiento social y cognitivo de cada partícula. Finalmente, la nueva posición de una partícula está determinada por su posición actual más la nueva velocidad calculada.

En el modelo PSO, las partículas buscan soluciones en un espacio con un rango $[s, -s]$. Para guiar efectivamente las partículas en el espacio de búsqueda, el movimiento máximo (velocidad máxima) debe encontrarse limitado por un rango $[-v_{max}, v_{max}]$. El valor de v_{max} es $p \cdot s$, con $0.1 \leq p \leq 1$. Usualmente se escoge $v_{max} = s$, es decir se considera $p = 1$.

4.2.2. Algoritmo PSO

El algoritmo funciona como se indica a continuación. Luego de inicializar las posiciones y velocidades de las partículas de forma aleatoria, comienzan las iteraciones. El primer paso es calcular

el *fitness* de cada partícula. El *fitness* representa la calidad de la solución candidata asociada a la posición de la partícula. Una vez que se dispone del *fitness*, es posible actualizar las variables *gbest* y *pbest_i*. Hecho eso, se procede a calcular las nuevas velocidades $v_i(k+1)$ y la nueva posición $x_i(k+1)$ para cada partícula. Tanto la posición como la velocidad debe saturarse si se alcanzan los límites predefinidos. Una vez realizado todo esto, se pasa a la siguiente iteración.

El proceso anterior se repite hasta llegar a uno de los criterios de término del algoritmo. Usualmente se usa como criterio de término la realización de un número determinado de iteraciones o si no un número fijo de iteraciones en que no hay mejora de la solución encontrada.

Una vez finalizado el algoritmo, la solución del problema está dada por *gbest*.

El Algoritmo 4.3 corresponde al pseudo-código de PSO que representa el algoritmo antes descrito. La función a minimizar es $f(\cdot)$ [20].

Algoritmo 4.3 Optimización de Enjambre de Partículas (PSO)

01. Inicializar el tamaño del enjambre de partículas n , y otros parámetros como ω , c_1 , c_2
 02. Inicializar las posiciones y las velocidades de las partículas aleatoriamente.
 03. Mientras no se cumpla el criterio de término
 04. $k = k + 1$
 05. $gbest(k) = \text{argmin}(f(gbest(k-1)), f(x_{_1}(k-1)), \dots, f(x_{_n}(k-1)))$
 06. Para $i = 1:n$
 08. $pbest_i(k) = \text{argmin}(f(pbest_i(k-1)), f(x_{_i}(k-1)))$
 09. Para $j = 1:d$
 10. $v_{_ij}(k+1) = \omega * v_{_ij}(k)$
 $+ c_1 * \phi_1 * (pbest(k) - x_{_ij}(k))$
 $+ c_2 * \phi_2 * (gbest(k) - x_{_ij}(k))$
 $x_{_ij}(k+1) = x_{_ij}(k) + v_{_ij}(k+1)$
 $x_{_i}$ pertenece a $[-s, s]$
 $v_{_i}$ pertenece a $[-v_max, v_max]$
 11. Siguiendo j
 12. Siguiendo i
 13. Finalizar
 14. La solución al problema de optimización está dada por $gbest(k)$
-

4.3. Nuevo algoritmo de identificación difusa

Una vez que se han especificado los fundamentos de los algoritmos genéticos (GA) y de la optimización por enjambre de partículas (PSO), en esta sección se presenta el nuevo método de identificación difusa desarrollado.

En la literatura existe otro método de identificación difusa que utiliza GA para su funcionamiento. En [9] se utiliza una aplicación de algoritmos genéticos para el diseño de sistemas difusos. La aplicación está orientada principalmente a la generación de las funciones de pertenencia del sistema. Tanto el número de funciones de pertenencia como su distribución se decide mediante algoritmos genéticos.

La codificación usada en [9] se explica a continuación: Se asume un número de funciones de pertenencia determinado. La forma de las funciones de pertenencia puede ser triangular, trapezoidal o polinomial. Cada función de pertenencia tiene un traslape de $1/2$ con sus vecinas. El string de GA representará la distancia existente entre ciertos hitos de funciones de pertenencia vecinas, tal como se muestra en la Figura 4.3.1. En el ejemplo se puede ver que el largo del string es $L=28$ y este se encuentra dividido en cuatro grupos de 7 bits. Producto de la evolución del algoritmo, irá variando la forma de las funciones de pertenencia a través de crossover y mutación, hasta alcanzar un conjunto óptimo de funciones de pertenencia.




Figura 4.3.1: Codificación binaria.

El nuevo método está orientado a la selección de del conjunto de reglas óptimo y, a diferencia de [9], no está orientado a la generación de las funciones de pertenencia del sistema. El esquema de funcionamiento general del método es el mismo que el presentado en la Figura 1.1.4. Primero se debe seleccionar una estructura del modelo, luego se identifican los parámetros de las premisas y luego los parámetros de las consecuencias.

La diferencia de este método con el que fue presentado en la Sección 1.1.2.2 es la forma en que se calcula cada una de las etapas. En este nuevo método los parámetros de las premisas son obtenidos mediante GA, mientras que los parámetros de las consecuencias son obtenidos mediante PSO.

A continuación se presenta el nuevo método de identificación difusa.

4.3.1. Elección de la estructura del modelo

La elección de la estructura del modelo no presenta innovación en este algoritmo. Es posible hacer un procedimiento de búsqueda exhaustiva de la estructura de regresores óptima para el modelo o si no se puede realizar una búsqueda la estructura por análisis de sensibilidad, como se explica en la Sección 1.1.2.2.

4.3.2. Identificación de los parámetros de las premisas

En este método también se obtienen los conjuntos difusos a partir de la partición mediante clustering difuso del conjunto de datos de entrenamiento. Para eso se deben aplicar los retardos indicados por los regresores al conjunto de datos de entrenamiento. Luego se aplica algún algoritmo de clustering que asigne grados de pertenencia a los N datos para cada uno de los C clusters difusos que se desean generar. En este trabajo se utilizó el algoritmo de clustering conocido como *Fuzzy C-Means* para particionar el conjunto de entrenamiento.

Una vez que se tienen los N datos clasificados en C clusters, cada cluster debe ser proyectado sobre el subespacio definido por cada uno de los K regresores que forman la estructura del modelo difuso. Se obtienen las funciones de pertenencia a cada conjunto difuso a partir de la interpolación de las proyecciones de cada cluster sobre los subespacios que genera cada regresor por alguna función adecuada. Típicamente las funciones utilizadas son sigmoideas y gaussianas. Hasta el momento el método no presenta innovación con respecto al método presentado en la Sección 1.1.2.2.

Una vez que se dispone de las funciones de pertenencia se deben generar las premisas de las reglas. Los antecedentes de una típica regla R_i tienen la siguiente forma:

$$R_i: \text{If } X_1 \text{ is } A_{1i} \text{ and } \dots \text{ and } X_k \text{ is } A_{ki}$$

Una primera opción sería generar premisas a partir de todas las combinaciones posibles de las funciones obtenidas anteriormente. Eso generaría un modelo de $M = C \cdot R$ reglas.

Muchas de esas reglas no tienen sentido, por lo que es necesario elaborar un método para seleccionar aquellas reglas que son significativas para la modelación y descartar las que no. Si se consideran en la modelación las reglas que no tienen sentido, al momento de calcular los parámetros de las premisas del modelo, es muy probable obtener modelos inestables.

Para realizar la selección óptima de reglas se recurrió a GA.

Se diseñó un cromosoma binario de $M = C \cdot R$ componentes. La componente i del cromosoma está asociada a la regla R_i . Si el bit i del cromosoma es 1, entonces la regla R_i será considerada en la modelación del sistema. Por otra parte, si el bit i es 0, entonces la regla R_i será descartada.




Figura 4.3.2: Cromosoma identificación de parámetros de las premisas.

El método funciona como se indica a continuación:

- Se inicializan los parámetros de probabilidad de mutación, probabilidad de crossover y criterio de término del algoritmo. Como criterio de término se utilizó un número máximo de iteraciones o un umbral mínimo de *fitness* alcanzado por alguno de los individuos.
- Se selecciona la estructura del modelo a identificar.
- Se realiza clustering difuso para particionar el espacio de entrada y se calculan proyecciones y funciones de pertenencia de los conjuntos difusos.
- Se inicializa una población de N_i individuos de manera aleatoria. Los individuos tienen el cromosoma antes descrito. Cada gen representa una posible regla.
- Se identifican los parámetros de las consecuencias de cada uno de los modelos generados a partir del genoma de cada individuo de la población.
- Se calcula el *fitness* de cada individuo de la población. El *fitness* corresponde al error cuadrático medio de la predicción a 1 paso generada con el modelo obtenido a partir del genoma de cada individuo.

- Se entra en el ciclo evolutivo. En cada ciclo:
 - Se eligen aquellos individuos con mejor *fitness*. Los individuos con mejor *fitness* serán los que tendrán mayor probabilidad de generar descendencia.
 - Se generan descendientes a partir del crossover del genoma de los mejores individuos de la generación anterior.
 - Se realizan mutaciones con cierta probabilidad al genoma de la descendencia.
 - Se identifican los parámetros de las consecuencias de cada uno de los modelos generados a partir del genoma de cada individuo de la nueva población.
 - Se calcula el *fitness* de cada individuo de la nueva población.
 - Sólo sobreviven los individuos con mejor *fitness*.
 - Si no se cumple criterio de término, se continúa con siguiente iteración. Si se cumple con el criterio de término, finaliza el método.

En la Figura 4.3.3 se muestra un diagrama de flujo con el método de identificación de parámetros de las premisas.

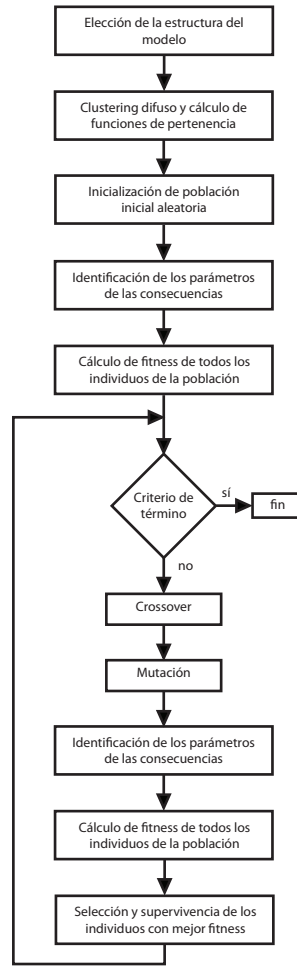


Figura 4.3.3: Diagrama de bloques proceso de selección de reglas mediante GA.

El esquema tradicional de identificación de parámetros de las consecuencias está basado en encontrar los parámetros por minimización de mínimos cuadrados. Para probar un esquema en que los parámetros de las premisas se calculan con el nuevo método y los parámetros de las consecuencias se calculan minimizando mínimos cuadrados, se utilizó la serie de Chen.

La ecuación (4.3.1) muestra la serie de Chen.

$$\begin{aligned}
 y(k) = & \left(0.8 - 0.5 \cdot e^{-y(k-1)^2}\right) \cdot y(k-1) - \left(0.3 + 0.9 \cdot e^{-y(k-1)^2}\right) \cdot y(k-2) \quad (4.3.1) \\
 & + u(k-1) + 0.2 \cdot u(k-2) + 0.1 \cdot u(k-1) \cdot u(k-2) + e(k)
 \end{aligned}$$

$y(k)$ corresponde a la salida del sistema, $u(k)$ a la entrada y $e(k)$ es ruido blanco.


Se inicializa la entrada $u(k)$ con una serie de diez mil números aleatorios y se genera la entrada $y(k)$ a partir de la serie de datos y de (4.3.1).

Para comparar resultados, se obtuvo un modelo ARX y un modelo difuso obtenido con el toolbox de Babuska [3], además del modelo obtenido con el nuevo método. Se realizaron predicciones a 1 paso con cada modelo.


Los parámetros de GA utilizados en el nuevo método de identificación fueron los siguientes:

- Número de individuos: 8
- Número máximo de iteraciones: 24
- Probabilidad de crossover: 0.6
- Probabilidad de mutación: 0.1


En la Figura 4.3.4 se muestran gráficos con las predicciones a 1 paso obtenidas con los distintos modelos.



(a) Modelo ARX



(b) Babuska



(c) Nuevo método (mínimos cuadrados)

Figura 4.3.4: Predicciones a 1 Paso de la Serie de Chen

En la Tabla 4.3.1 se muestran los índices de desempeño de cada modelo en la predicción a 1 paso.

Cuadro 4.3.1: Predicción a 1 Paso

Modelo	ECM	VAF
Serie de Chen ARX	0.2973	91.1629 %
Serie de Chen Babuska	0.1593	97.4621 %
Serie de Chen Nuevo Método (Mín. Cuadrados)	0.2286	94.7748 %

4.3.3. Identificación de los parámetros de las consecuencias con PSO

Se diseñó un nuevo método de identificación de parámetros de las consecuencias de las reglas. A diferencia del método presentado en la Sección 1.1.2.2, en el nuevo método los parámetros de las consecuencias se obtendrán por optimización por enjambre de partículas en vez de utilizar un

método algebraico.

Una regla R_i del sistema difuso tiene la siguiente forma:

$$R_i: \text{If } X_1 \text{ is } A_{1i} \text{ and } \dots \text{ and } X_k \text{ is } A_{ki} \text{ then } Y_i = p_o^i + p_1^i \cdot X_1 + \dots + p_k^i \cdot X_k.$$

En donde:

X_1, \dots, X_k son las variables de entrada o premisas de las reglas.

A_{1i}, \dots, A_{ki} son los conjuntos difusos asociados a las variables de entrada.

Y_i es la salida de la regla i .

p_o^i, \dots, p_k^i corresponden a los parámetros de la función lineal de salida de la regla.

Un individuo de la población utilizada para calcular los parámetros de las premisas de las reglas representa a un conjunto candidato de reglas. Dado ese conjunto candidato de reglas, en esta etapa se deben calcular parámetros p_o^i, \dots, p_k^i para cada regla i , de tal forma que el error cuadrático medio de la predicción a 1 paso del modelo sea mínimo.

Dado que se trabajará con PSO para encontrar los parámetros de las consecuencias, es necesario definir correctamente la partícula que se utilizará. Cada una de las partículas a utilizar en la búsqueda del conjunto de parámetros óptimo corresponde a un vector de números de punto flotante de dimensión $K \cdot M$. K corresponde al número de regresores del sistema, mientras que M corresponde al número de reglas del individuo GA con la combinación de reglas candidatas.

Una partícula j es un único vector que contiene parámetros candidatos para cada una de las reglas definidas por las premisas. En (4.3.2) se muestra un ejemplo de partícula.

$$part_j = \left[p_o^1 \quad p_1^1 \quad \dots \quad p_k^1 \quad p_o^2 \quad p_1^2 \quad \dots \quad p_k^2 \quad \dots \quad p_o^i \quad p_1^i \quad \dots \quad p_k^i \quad \dots \quad p_o^M \quad p_1^M \quad \dots \quad p_k^M \right]^T \quad (4.3.2)$$

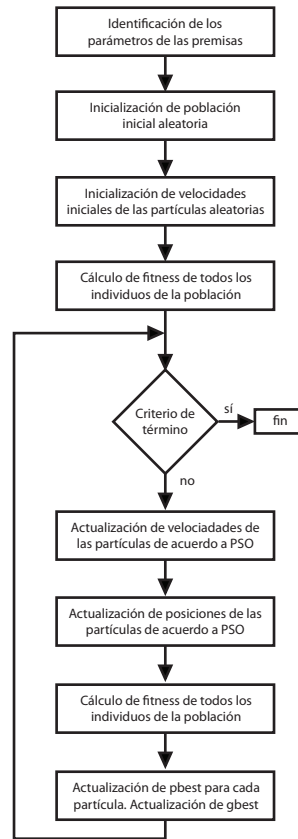


Figura 4.3.5: Diagrama de bloques proceso de estimación de parámetros de las consecuencias mediante PSO.

El método funciona como se indica a continuación:

- Se realiza identificación de los parámetros de las premisas.
- Se inicializan parámetros de PSO. Los parámetros de PSO corresponden al número de partículas con el que se trabajará, al coeficiente social y al coeficiente cognitivo. Se inicializa criterio de término de PSO, que corresponde a un número máximo de iteraciones o un número máximo de iteraciones en que la partícula mejor evaluada no cambia.
- Se inicializan posiciones y velocidades aleatorias de todas las partículas. En todo momento las posiciones de las partículas se mantendrán acotadas al intervalo $(-1, 1)$, porque se desea que los parámetros p_k^i se mantengan acotados en ese rango. Las velocidades siempre se mantendrán acotadas al intervalo $(-0.2, 0.2)$ para evitar una saturación muy rápida de las posiciones.
- Se calcula el *fitness* de todas las partículas y se calculan valores de *pbest_j* y *gbest*. El *fitness*

de la partícula j corresponde al error cuadrático medio de la simulación a 1 paso del modelo obtenido a partir de los parámetros de las consecuencias representados por la posición actual de j .

- Se entra en el ciclo evolutivo. En cada ciclo:
 - Se actualiza la velocidad de cada partícula j . Para eso se utiliza la definición de la actualización de velocidades del algoritmo PSO.
 - Se actualiza la posición de cada partícula j . Para eso se utiliza la definición de la actualización de posiciones del algoritmo PSO.
 - Cálculo de *fitness* de cada partícula j .
 - Actualización de $pbest_j$ y $gbest$.
 - Si se cumple alguno de los criterios de término, se termina el algoritmo y la mejor solución al problema es $gbest$. En caso contrario, se prosigue con la siguiente iteración.

Se realizó identificación de la serie de Chen (4.3.1) para probar este nuevo método. Los parámetros de PSO utilizados en el nuevo método de identificación fueron los siguientes:

- Número de partículas: 6
- Número máximo de iteraciones: 30

En la Figura 5.7.1 se muestra el gráfico con la predicción a 1 paso obtenida con el nuevo método y PSO.




Figura 4.3.6: Resultados predicción a 1 paso - Nuevo método PSO

En la Tabla 4.3.2 se incorporan los índices de desempeño de esta nueva forma de identificación.

Cuadro 4.3.2: Predicción a 1 Paso

Modelo	ECM	VAF
Serie de Chen ARX	0.2973	91.1629 %
Serie de Chen Babuska	0.1593	97.4621 %
Serie de Chen Nuevo Método (Mín. Cuadrados)	0.2286	94.7748 %
Serie de Chen Nuevo Método (PSO)	0.2337	94.5422 %

4.4. Número de iteraciones algoritmo

La motivación de utilizar inteligencia computacional para la selección de reglas es evitar realizar un gran número de iteraciones realizando una búsqueda exhaustiva de la combinación óptima de reglas.

Se hizo una estimación de iteraciones con ambos métodos para tener una idea de la mejora en esfuerzo computacional que se obtiene al usar el nuevo método basado en inteligencia computacional.

4.4.1. Búsqueda exhaustiva

A continuación se muestra el cálculo para estimar la cantidad de modelos difusos a evaluar para la búsqueda exhaustiva de un modelo óptimo.

Suponiendo que el espacio de entradas está formado por R regresores y que éste fue particionado en C clusters, entonces un modelo que contenga todas las reglas generadas a partir de todas las combinaciones posibles de funciones de pertenencia tendrá M_{max} reglas. M_{max} está dado por:

$$M_{max} = C^R \quad (4.4.1)$$

El número de combinaciones posibles de r elementos, sobre un grupo de n elementos está dado por:

$$\binom{n}{r} = \frac{n!}{r!(n-r)!} \quad (4.4.2)$$

Por lo tanto, si contamos todos los modelos posibles que podemos formar con $2, 3, \dots, C^{R-1}, C^R$ reglas, el número de modelos posibles está dado por:

$$N_{mod} = \sum_{i=2}^{C^R} \binom{C^R}{i} \quad (4.4.3)$$

Desarrollando, se tiene:

$$N_{mod} = (C^R)! \sum_{i=2}^{C^R} \frac{1}{i! (C^R - i)!} \quad (4.4.4)$$

Si se considera un modelo de $R = 5$ regresores y $C = 2$ clusters, el número de modelos a evaluar será:

$$N_{mod} = 4294967263 \quad (4.4.5)$$

4.4.2. Búsqueda por GA

Suponiendo que se tiene una población de N individuos que evoluciona durante I_{max} iteraciones. Si la probabilidad de crossover entre $\alpha \cdot N$ de los mejores individuos es P_c y la probabilidad de mutación es P_m , entonces, aproximadamente, la cantidad de modelos a evaluar será:

$$N_{mod} = (\alpha \cdot N)^2 \cdot (P_c + P_m) \cdot I_{max} \quad (4.4.6)$$

Suponiendo $N = 8$, $\alpha = 0.5$, $I_{max} = 24$, $P_c = 0.6$ y $P_m = 0.1$, entonces:

$$N_{mod} = 269 \quad (4.4.7)$$

4.5. Discusión

En este capítulo se presentó un nuevo método de identificación difusa basado en GA y PSO. GA se utiliza para seleccionar una base de reglas adecuada para el sistema, mientras que PSO se utiliza para encontrar los parámetros de las consecuencias de las reglas de dicha base.

El método propuesto permite encontrar una base de reglas adecuada para el sistema en un número de iteraciones considerablemente menor que usando una búsqueda exhaustiva.

En el capítulo siguiente se probará el método con datos de entrada y salida obtenidos a partir del simulador del aerogenerador.

Capítulo 5

Aplicación del algoritmo de identificación para la obtención de un modelo del aerogenerador

5.1. Set de datos para la identificación del sistema

El desempeño del algoritmo se midió en base al error cuadrático medio de las predicciones a 1, 10 y N pasos de los modelos obtenidos y se compararon con los resultados obtenidos a partir de modelos ARX y difusos basados en el toolbox de Babuska.

En los tres casos se hizo identificación en lazo cerrado. Dado que este tipo de plantas requieren estar controladas en todo momento por razones de seguridad, es la situación más cercana a la realidad para realizar una identificación.

Se trabajó con conjuntos de entrenamiento y validación. El tiempo de muestreo utilizado fue de 0.5 [s]. Se tomaron 40,000 muestras en un periodo de simulación de 20,000 [s].

Las variables de entrada de los modelos son velocidad del viento (v) y ángulo de ataque de las palas (θ). La variable de salida es la potencia activa generada (P). Se trabajó con datos normalizados.

En todo momento se mantuvo el variador de frecuencia entregando voltaje $v = \theta$ a los bornes

del rotor con el fin de simplificar el análisis. De esta forma, el sistema identificado corresponde al tipo de aerogeneradores en que no se aplica doble alimentación del generador (DFIG), que es la tecnología presente actualmente en Chile.

En la Figura 5.1.1 se presenta el diagrama de bloques del simulador del aerogenerador completo.

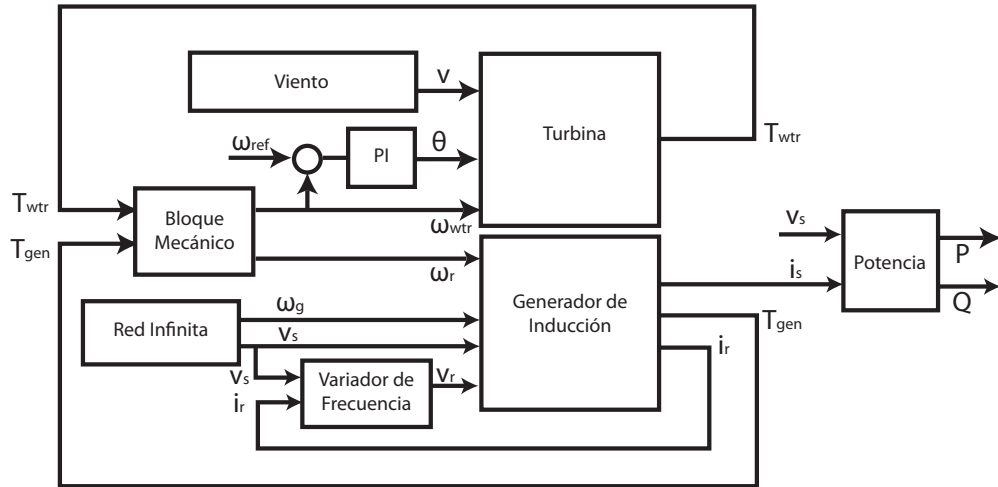


Figura 5.1.1: Diagrama de bloques integrado.

Se tomó un primer set de datos. En la Figura 5.1.2 se muestra un detalle de ellos.




Figura 5.1.2: Set de datos

Para realizar identificación de sistemas, las variables de entrada deben presentar una correlación baja. En el caso de este sistema, dada la existencia de un lazo cerrado de control, existe un acoplamiento entre las variables de entrada: el ángulo θ depende de la velocidad de giro de la turbina ω_{wt} , mientras que esta última depende de la velocidad del viento v y del mismo ángulo θ en instantes previos. Por lo tanto, existe acoplamiento entre las variables de entrada θ y v .

Para medir el acoplamiento se graficó en índice de correlación entre las variables θ y v con distintos retrasos. El gráfico se muestra en la Figura 5.1.3.




Figura 5.1.3: Correlación θ v/s v .

Se puede apreciar que el índice de correlación alcanza un máximo de 0.8 en torno a los 3 [s] de retardo entre las variables. Para obtener un conjunto de datos con menor índice de correlación entre las entradas, se intervino el controlador [2].

El controlador proporcional-integral (PI) continuo genera acciones de control de acuerdo a (5.1.1):

$$u(t) = K_p \cdot (r(t) - y(t)) + K_i \cdot \int_0^t (r(\alpha) - y(\alpha)) d\alpha \quad (5.1.1)$$

Se interviene la parte proporcional del controlador, introduciendo ruido blanco, como se indica en (5.1.2).

$$u(t) = K_p \cdot (1 + v(t)) \cdot (r(t) - y(t)) + K_i \cdot \int_0^t (r(\alpha) - y(\alpha)) d\alpha \quad (5.1.2)$$

En (5.1.2), $v(t)$ corresponde a una función generadora de ruido blanco.

Se tomó un segundo set de datos. En la Figura 5.1.4 se muestra un detalle de ellos.




Figura 5.1.4: Segundo set de datos

Para medir el acoplamiento se graficó en índice de correlación entre las variables θ y v con distintos retrasos. El gráfico se muestra en la Figura 5.1.5.




Figura 5.1.5: Correlación θ v/s v. Set de datos alternativo.

Se puede apreciar que el índice de correlación alcanza un máximo de 0.66 en torno a los 3 [s] de retardo entre las variables.

Todos los modelos obtenidos tienen como objetivo formar parte de un sistema de control predictivo. En este tipo de controladores las acciones de control son generadas por un optimizador. En la optimización se toman en cuenta tanto la historia de cada regresor como su proyección a futuro, generando una acción de control, que minimiza una función objetivo y que será aplicada en el instante siguiente al actual.

Dado que al momento de la creación de los modelos predictivos aún no se dispone del controlador,

no hay forma de generar las acciones de control futuras del sistema. Además, tampoco hay forma de generar valores futuros de la velocidad de viento, porque no se dispone de un estimador de velocidad de viento a corto plazo.

Cada problema se abordó de la siguiente forma:

1. El problema de las acciones de control se solucionó utilizando valores futuros al actual de la variable θ del conjunto de datos de validación. Esto es válido, porque θ corresponde a la variable manipulada del sistema; por lo que ésta es una variable independiente y puede ser modificada a discreción.
2. La velocidad del viento corresponde a una perturbación medida del sistema. No sería correcto generar valores independientes de velocidad de viento, porque el viento tiene un comportamiento estadístico particular y se requiere un predictor de para obtener datos coherentes con la realidad. En este trabajo no se abordó el tema de predicción de viento, por lo que se optó por dos estrategias para realizar estimaciones de la velocidad del viento para las predicciones de 10 y N pasos.
 - a) De la misma forma que con la variable manipulada, utilizar valores futuros al actual de la variable v del conjunto de datos de validación.
 - b) Si se está trabajando actualmente en el instante de tiempo k , utilizar durante todo el horizonte de predicción un promedio de los valores de velocidad de viento comprendidos entre los instantes pasados $k - a$ y $k - 1$, siendo a un valor a definir. En este trabajo se seleccionó en forma empírica un valor $a=5$.

5.2. Análisis de sensibilidad del nuevo algoritmo

Tanto los algoritmos genéticos (GA) como la optimización por enjambre de partículas (PSO) utilizan una serie de parámetros para su funcionamiento. Los valores de dichos parámetros afectan al desempeño de ambos métodos, por lo que son considerados parámetros de sensibilidad de estos [19]. Dado que el método de identificación está basado en GA y PSO, fue necesario hacer análisis de sensibilidad del método para encontrar parámetros adecuados para la obtención de modelos difusos.

El nuevo método de identificación difusa arroja distintos resultados cada vez que es ejecutado. Esto se debe a que tanto GA como PSO utilizan números aleatorios para su ejecución, lo que afecta a los resultados finales. Por esa razón no basta con hacer una sola ejecución del método para obtener un punto de sensibilidad. Eso arrojaría valores poco representativos.

Para obtener cada punto de sensibilidad se hizo variar un parámetro a la vez, manteniendo constantes los demás. Por cada punto de sensibilidad se realizaron réplicas hasta que la varianza de la media del error cuadrático medio de todas las réplicas se mantenga estable.

Estudios recientes muestran que el rol del coeficiente de inercia ω es crítico para el comportamiento de convergencia de PSO [20]. Este coeficiente controla el impacto de las velocidades previas sobre la actual. Un factor de inercia grande beneficia una exploración global, mientras que uno pequeño tiende a facilitar la exploración local [19]. Algunos estudios [24] proponen el uso de un coeficiente de inercia variable, que parte en 0.9 al comienzo de las iteraciones y que termine en 0.4. De este modo se favorece la búsqueda global al comienzo de las iteraciones y al final se privilegia la búsqueda en torno a las soluciones encontradas hasta el momento.

Según [19], los coeficientes cognitivos y sociales, c_1 y c_2 respectivamente, no son críticos para la convergencia de PSO. Sin embargo una buena sintonización fina puede resultar en una convergencia más rápida y evasión de mínimos locales.

Por lo anterior, durante el análisis de sensibilidad se usaron los siguientes valores de ω , c_1 y c_2 :

- $\omega = 0.9 - \frac{(0.9-0.4) \cdot i}{N_{it}}$, en donde i es el número de iteración PSO y N_{it} es el número máximo de iteraciones considerado
- $c_1 = 1$
- $c_2 = 1$

Se hizo análisis de sensibilidad con respecto a los siguientes parámetros:

- Algoritmo Genético
 - Número de individuos.
 - Número de iteraciones.
 - Probabilidad de crossover.
 - Probabilidad de mutación.

- Optimización por enjambre de partículas
 - Número de partículas.
 - Número de iteraciones.

Mediante pruebas empíricas, se seleccionaron los siguientes valores de partida para el método:


- Algoritmo Genético
 - Número de individuos: 10
 - Número de iteraciones: 20
 - Probabilidad de crossover: 0,6
 - Probabilidad de mutación: 0,1

- Optimización por enjambre de partículas
 - Número de partículas: 10
 - Número de iteraciones: 25


A continuación se presentan los resultados del análisis de sensibilidad.

5.2.1. GA: Número de individuos


A continuación se muestran los resultados correspondientes al análisis de sensibilidad correspondiente al parámetro “Número de Individuos”, utilizado en GA.




(a) Predicción 1 Paso




(b) Predicción 10 Pasos



(c) Predicción 10 Pasos (viento promedio)



(d) Predicción N Pasos



(e) Predicción N Pasos (viento promedio)


Figura 5.2.1: Análisis de sensibilidad - ECM v/s Número de Individuos GA.

Analizando el gráfico de predicción a 1 paso de esta etapa de análisis de sensibilidad, se aprecia que al incrementar el número de individuos, el error cuadrático medio de la predicción tiende a disminuir. Al incrementar el número de individuos, se incrementa también el tiempo computacional


de cálculo. Se eligió un número de 8 individuos para GA.

5.2.2. GA: Número de iteraciones


A continuación se muestran los resultados correspondientes al análisis de sensibilidad correspondiente al parámetro “Número de Iteraciones”, utilizado en GA.




(a) Predicción 1 Paso




(b) Predicción 10 Pasos



(c) Predicción 10 Pasos (viento promedio)



(d) Predicción N Pasos



(e) Predicción N Pasos (viento promedio)


Figura 5.2.2: Análisis de sensibilidad - ECM v/s Número de Iteraciones GA.

Según se puede apreciar en los gráficos, no es muy clara la relación entre el número de iteraciones


y el error cuadrático medio de las predicciones. Se aprecia una disminución abrupta, tipo escalón, del error cuadrático medio en torno a las 20 iteraciones, por lo que se decidió trabajar con valores de este parámetro sobre 20. Se eligió un número de 24 iteraciones para GA.

5.2.3. GA: Probabilidad de crossover


A continuación se muestran los resultados correspondientes al análisis de sensibilidad correspondiente al parámetro “Probabilidad de Crossover”, utilizado en GA.




(a) Predicción 1 Paso




(b) Predicción 10 Pasos



(c) Predicción 10 Pasos (viento promedio)



(d) Predicción N Pasos




(e) Predicción N Pasos (viento promedio)

Figura 5.2.3: Análisis de sensibilidad - ECM v/s Probabilidad de Crossover GA.


En la predicción a 1 paso no se aprecia un efecto importante de la probabilidad de crossover sobre los resultados. Sin embargo, en la predicción a 10 pasos se aprecia una disminución sostenida del error cuadrático medio al aumentar la probabilidad de crossover. Se eligió una probabilidad de crossover de 0,6. Cabe recordar que al aumentar esta probabilidad, aumenta la cantidad de descendencia en cada iteración. Dicho aumento en la descendencia aumenta el esfuerzo computacional, por lo que no es conveniente elegir valores demasiado altos.

5.2.4. GA: Probabilidad de mutación


A continuación se muestran los resultados correspondientes al análisis de sensibilidad correspondiente al parámetro “Probabilidad de Mutación”, utilizado en GA.




(a) Predicción 1 Paso




(b) Predicción 10 Pasos



(c) Predicción 10 Pasos (viento promedio)



(d) Predicción N Pasos



(e) Predicción N Pasos (viento promedio)

Figura 5.2.4: Análisis de sensibilidad - ECM v/s Probabilidad de Mutación GA.

La probabilidad de mutación parece no afectar mucho a los resultados, por lo que se mantuvo en 0,1. Cabe recordar que al aumentar esta probabilidad, aumenta la cantidad de descendencia en cada iteración. Valores muy altos de este parámetros aumentan el esfuerzo computacional.

5.2.5. PSO: Número de partículas

A continuación se muestran los resultados correspondientes al análisis de sensibilidad correspondiente al parámetro “Número de Partículas”, utilizado en PSO.





Figura 5.2.5: Análisis de sensibilidad - ECM v/s Número de Partículas PSO.

En los gráficos se puede apreciar que el número de partículas es gravitante para el resultado del método. El valor del error cuadrático medio tiende a disminuir a medida que se aumenta el número de partículas, valor que tiende a estabilizarse en torno a las 6 partículas. Para no aumentar


demasiado el esfuerzo computacional y obtener resultados satisfactorios, se eligió trabajar con un número de 6 partículas PSO.

5.2.6. PSO: Número de iteraciones


A continuación se muestran los resultados correspondientes al análisis de sensibilidad correspondiente al parámetro “Número de Iteraciones”, utilizado en PSO.




(a) Predicción 1 Paso



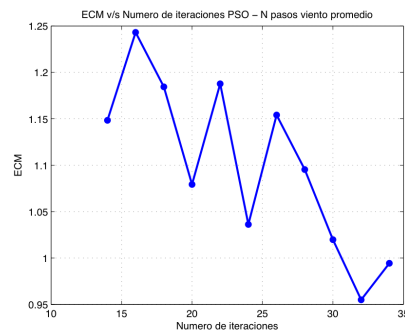
(b) Predicción 10 Pasos



(c) Predicción 10 Pasos (viento promedio)



(d) Predicción N Pasos



(e) Predicción N Pasos (viento promedio)

Figura 5.2.6: Análisis de sensibilidad - ECM v/s Número de Iteraciones PSO.

A partir de los gráficos, es posible concluir que el número de iteraciones de PSO es un parámetro muy importante para los resultados del método. El gráfico de predicciones a 1 paso presenta un punto rodilla en torno a las 20 iteraciones; sin embargo se eligió un valor de 30 iteraciones para trabajar con el método, porque el método resultó ser muy sensible a este parámetro.

5.2.7. Parámetros seleccionados

En la Tabla 5.2.1 se presenta un resumen de los parámetros utilizados en el método.

Cuadro 5.2.1: Resumen de parámetros obtenidos por análisis de sensibilidad.

Parámetro	Valor
Número de individuos (GA)	8
Número de iteraciones (GA)	24
Probabilidad de crossover (GA)	0.6
Probabilidad de mutación (GA)	0.1
Coficiente de inercia ω (PSO)	[0.9; 0.4]
Coficiente cognitivos c_1 (PSO)	1
Coficiente social c_2 (PSO)	1
Número de partículas (PSO)	6
Número de iteraciones (PSO)	30

5.3. Modelo ARX

Se obtuvieron dos modelos ARX. El primero corresponde a un modelo obtenido por búsqueda exhaustiva, mientras que el segundo se obtuvo mediante análisis de sensibilidad.

En el dominio Z los modelos tienen la estructura mostrada en (5.3.1).

$$A(z)P(z) = B_1(z)V(z) + B_2(z)\Theta(z) + e(t) \quad (5.3.1)$$

En donde $A(z)$, $B_1(z)$ y $B_2(z)$ son polinomios.

5.3.1. Modelo obtenido por búsqueda exhaustiva

Para obtener este modelo se generaron todos los modelos resultantes de usar todas las combinaciones de los siguientes regresores:

$$\begin{array}{cccccc} P(k-1) & P(k-2) & P(k-3) & P(k-4) & P(k-5) & P(k-6) \\ v(k-1) & v(k-2) & v(k-3) & v(k-4) & v(k-5) & v(k-6) \\ \theta(k-1) & \theta(k-2) & \theta(k-3) & \theta(k-4) & \theta(k-5) & \theta(k-6) \end{array} \quad (5.3.2)$$

Según la nomenclatura utilizada en Matlab los regresores utilizados en el modelo quedan completamente descritos por las variables N_y , N_u y N_d .

La variable N_y indica el orden del polinomio $A(z)$. El orden de este polinomio corresponde al número de polos del sistema lineal.

La variable N_u indica al orden del polinomio $B(z)$, por lo que corresponde al número de ceros del sistema lineal más un cero extra. Para sistemas de múltiples entradas, N_u es un vector con tantas componentes como entradas tenga el sistema. La componente i de N_u está asociada a la entrada i del sistema.

La variable N_d corresponde al número de instantes de tiempo que transcurren antes que la entrada afecte a la salida del sistema. También se conoce como *tiempo muerto* del sistema. Al igual que en el caso de N_u , para sistemas de múltiples entradas N_d es un vector de tantas componentes como entradas tenga el sistema. La componente i de N_d está asociada al retardo de la entrada i del sistema.

A partir de los modelos obtenidos, se seleccionó el modelo con menor error cuadrático medio en

la predicción a 1 paso. En (5.3.3) se describe el conjunto de regresores que forman el modelo que cumple el criterio de menor error cuadrático medio entre todos los modelos calculados.

$$\begin{aligned} N_y &= 1 \\ N_u &= \begin{bmatrix} 2 & 1 \end{bmatrix} \\ N_d &= \begin{bmatrix} 1 & 3 \end{bmatrix} \end{aligned} \quad (5.3.3)$$

En la Ecuación (5.3.4) se presentan los polinomios $A(z)$, $B_1(z)$, $B_2(z)$, correspondientes al mejor modelo obtenido por esta metodología.

$$\begin{aligned} A(z) &= 1 - 0.9629 \cdot z^{-1} \\ B_1(z) &= -0.524 \cdot z^{-1} + 0.4238 \cdot z^{-2} \\ B_2(z) &= 0.1444 \cdot z^{-3} \end{aligned} \quad (5.3.4)$$

En (5.3.5) se muestra el modelo en el dominio del tiempo discreto.

$$P(k) = 0.9629 \cdot P(k-1) - 0.524 \cdot v(k-1) + 0.4238 \cdot v(k-2) + 0.1444 \cdot \theta(k-3) \quad (5.3.5)$$


En la Tabla 5.3.1 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo 5.3.5.

Cuadro 5.3.1: Resultados modelo ARX obtenido por búsqueda exhaustiva.


Prueba	ECM	VAF
Predicción 1 Paso	0,1068	98,8593 %
Predicción 10 Pasos (Viento Conocido)	0,2829	91,9849 %
Predicción 10 Pasos (Viento Promedio)	0,5529	69,3757 %
Predicción N Pasos (Viento Conocido)	0,5039	74,6055 %
Predicción N Pasos (Viento Promedio)	0,6329	59,9473 %

A modo de ilustración acerca del desempeño del sistema (5.3.5) frente de las distintas predicciones propuestas, en la Figura 5.3.1 se muestran gráficos de una parte de las predicciones realizadas


con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 pasos



(c) N pasos

Figura 5.3.1: Predicciones modelo ARX obtenido por búsqueda exhaustiva.

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.

5.3.2. Modelo obtenido por análisis de sensibilidad

Al realizar una selección de modelos por búsqueda exhaustiva se deben calcular $M = N^2 - 1$ modelos distintos, en donde N corresponde al número de regresores total a considerar en la modelación y M a la cantidad de combinaciones posibles que se pueden obtener a partir de los regresores mencionados. Además del cálculo de los modelos, cada uno de ellos se debe evaluar con los datos del conjunto de validación para realizar predicciones y poder medir su calidad.

Considerando que para la búsqueda exhaustiva de un modelo ARX se utilizaron $N = 18$ regresores, la cantidad de modelos que se calcularon y evaluaron corresponde a $M = 262143$, lo que

involucra un esfuerzo computacional considerable.

Para evitar la evaluación de una cantidad tan elevada de modelos, existen métodos de selección de regresores por análisis de sensibilidad. Estos métodos se basan en la idea que hay ciertos regresores que aportan más información al sistema que otros. Los métodos buscan identificar aquellos regresores significativos para formar un modelo con ellos. Estos métodos, por lo general, logran obtener un modelo final tan solo evaluando N modelos candidatos, en donde N corresponde al número de regresores total a considerar en la modelación.

En este trabajo se utilizó un método conocido como método de regresión por pasos. Inicialmente se comienza con un modelo vacío. En cada iteración se identificarán los regresores más significativos para la modelación mediante el cálculo de un índice estadístico adecuado y se incorporará el regresor más significativo a la modelación, siempre y cuando su incorporación refleje una disminución el error cuadrático medio del nuevo modelo con respecto al anterior.

A continuación se detalla como funciona el algoritmo:

Criterio de inclusión de nuevo regresor Se agregará el regresor seleccionado si el *error cuadrático medio* del modelo obtenido al agregar la nueva componente disminuye con respecto al modelo anterior.

Paso 1. Determinar cual regresor X_k es el más significativo con relación a la salida del sistema Y . En esta etapa se utiliza el índice (5.3.6), denominado coeficiente de correlación.

$$\rho_{XY} = \frac{\sigma_{XY}}{\sigma_x \cdot \sigma_Y} \quad (5.3.6)$$

En donde σ_{XY} corresponde a la covarianza entre X e Y, definida por la ecuación (5.3.7).

$$\sigma_{XY} = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y}) \quad (5.3.7)$$

σ_X corresponde a la desviación estándar de X, definida en la ecuación (5.3.8).

$$\sigma_X = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2} \quad (5.3.8)$$

1. Usando el conjunto de datos de entrenamiento, se calculó el coeficiente de correlación de todas

las componentes candidatas con respecto a la salida.

2. Se incluye a la modelación aquella componente con mayor índice de correlación ρ . Se retira dicha componente del conjunto de componentes candidatas, pues ya fue incluida en la modelación.
3. Se realiza una simulación a 1 paso y se obtiene la salida aproximada $\hat{Y}(k)$.
4. Se calcula el residuo $e_1(k) = Y(k) - \hat{Y}(k)$.

Paso n. Agregar nueva componente X_k al modelo.

1. Se calcula el coeficiente de correlación entre las restantes componentes candidatas y el residuo obtenido en el paso anterior $e_{n-1}(k)$. Se genera un ranking a partir del índice. Si no quedan variables candidatas por incluir, se termina con el algoritmo.
2. Se aplica criterio de inclusión a la variable candidata con mejor ranking. Hay tres escenarios posibles:
 - a) Si se cumple criterio de inclusión, se incluye a la modelación aquella componente. Se retira dicha componente del conjunto de componentes candidatas, pues ya fue incluida en la modelación. Se prosigue con paso 3.
 - b) Si no se cumple el criterio de inclusión, no se incluye la variable candidata en la modelación. Ésta se elimina tanto del ranking como de la lista de variables candidatas por incluir. Se vuelve a paso 2.
 - c) Si no hay variables en el ranking, se finaliza el algoritmo
3. Se forma un nuevo modelo incluyendo la componente X_k seleccionada. Se retira dicha componente del conjunto de componentes candidatas, pues ya fue incluida en la modelación.
4. Se realiza una simulación a 1 paso y se obtiene la salida aproximada $\hat{Y}(k)$.
5. Se calcula el residuo $e_n(k) = Y(k) - \hat{Y}(k)$.

Se aplicó el algoritmo al caso de estudio, utilizando los regresores presentados en (5.3.2). Se evaluaron $N = 18$ modelos en total y se seleccionó aquel con menor *error cuadrático medio*. En (5.3.9)

se describe el conjunto de regresores que forman el modelo que cumple el criterio de menor error cuadrático medio entre todos los modelos calculados.

$$\begin{aligned}
 N_y &= 2 \\
 N_u &= \begin{bmatrix} 1 & 1 \end{bmatrix} \\
 N_d &= \begin{bmatrix} 1 & 3 \end{bmatrix}
 \end{aligned}
 \tag{5.3.9}$$

En la (5.3.10) se presentan los polinomios $A(z)$, $B_1(z)$, $B_2(z)$, correspondientes al mejor modelo obtenido por esta metodología.

$$\begin{aligned}
 A(z) &= 1 - 1.193z^{-1} + 0.2188z^{-2} \\
 B_1(z) &= -0.06801z^{-1} \\
 B_2(z) &= 0.09959z^{-3}
 \end{aligned}
 \tag{5.3.10}$$

En (5.3.11) se muestra el modelo en el dominio del tiempo discreto.

$$P(k) = 1.193 \cdot P(k-1) - 0.2188 \cdot P(k-2) - 0.06801 \cdot v(k-1) + 0.09959 \cdot \theta(k-3) \tag{5.3.11}$$

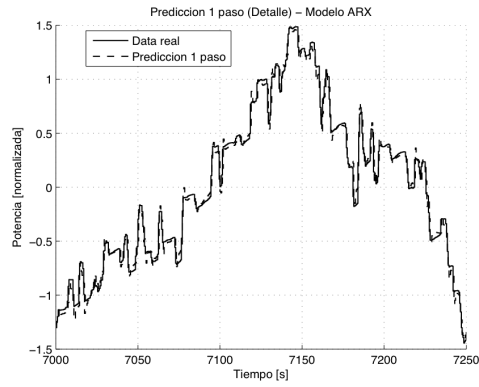
En la Tabla 5.3.2 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo (5.3.11).

Cuadro 5.3.2: Resultados modelo ARX obtenido por análisis de sensibilidad.


Prueba	ECM	VAF
Predicción 1 Paso	0.1070	98.8553 %
Predicción 10 Pasos (Viento Conocido)	0.6120	62.4960 %
Predicción 10 Pasos (Viento Promedio)	0.6375	59.2909 %
Predicción N Pasos (Viento Conocido)	0.5738	67.0800 %
Predicción N Pasos (Viento Promedio)	0.6282	60.5340 %

A modo de ilustración acerca del desempeño del sistema (5.3.11) frente de las distintas predic-


ciones propuestas, en la Figura 5.3.2 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.3.2: Predicciones modelo ARX obtenido por análisis de sensibilidad.

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.

5.4. Modelo Babuska

5.4.1. Modelo obtenido por búsqueda exhaustiva

Al igual que para el modelo ARX, se generaron todas las combinaciones posibles de los regresores presentados en (5.3.2) y se calcularon modelos con cada una de las combinaciones usando el toolbox de Babuska.

En este caso, además de encontrar los coeficientes N_y , N_u y N_d correspondientes al modelo óptimo, se debe encontrar el número de clusters C correspondiente al modelo que arroja resultados óptimos.

A partir de los modelos obtenidos, se seleccionó el modelo con menor *error cuadrático medio* en la predicción a 1 paso. En (5.4.1) se describe el conjunto de regresores que forman el modelo que cumple el criterio de menor error cuadrático medio entre todos los modelos calculados, además del número de clusters C correspondiente al modelo.

$$\begin{aligned} C &= 2 \\ N_y &= 1 \\ N_u &= \begin{bmatrix} 3 & 1 \end{bmatrix} \\ N_d &= \begin{bmatrix} 1 & 2 \end{bmatrix} \end{aligned} \tag{5.4.1}$$

Como parámetro del clustering difuso se usó un índice de fusificación $m = 1.5$.

Las funciones de pertenencia obtenidas corresponden a gaussianas dobles, definidas por la Ecuación (5.4.2)

$$\mu_{A_{ij}}(x) = \begin{cases} e^{-\frac{(x-a_1)^2}{2 \cdot b_1}} & x < a_1 \\ 1 & a_1 < x < a_2 \\ e^{-\frac{(x-a_2)^2}{2 \cdot b_2}} & a_2 < x \end{cases} \tag{5.4.2}$$

en donde $\mu_{A_{ij}}$ corresponde a la función de pertenencia del conjunto difuso A_{ij} , asociado al regresor j de la regla i .

Las reglas tienen la siguiente forma:

$$R_i: \text{ If } X_1 \text{ is } A_{1i} \text{ and } \dots \text{ and } X_k \text{ is } A_{ki} \text{ then } Y_i = p_o^i + p_1^i \cdot X_1 + \dots + p_k^i \cdot X_k,$$

en donde:

X_1, \dots, X_k son las variables de entrada o premisas de las reglas.

A_{1i}, \dots, A_{ki} son los conjuntos difusos asociados a las variables de entrada.

Y_i es la salida de la regla i .

Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (5.4.3).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (5.4.3)$$

En la función (5.4.3), w_r corresponde al grado de activación de la regla r . En (5.4.4) se muestra la definición de w_r .


$$w_r = \mu_1^r \cdot \dots \cdot \mu_i^r \cdot \dots \cdot \mu_{n_y+n_u}^r \quad (5.4.4)$$

En la Tabla 5.4.1 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro 5.4.1: Resultados modelo difuso Babuska obtenido por búsqueda exhaustiva.

Prueba	ECM	VAF
Predicción 1 Paso	0.1612	97.4008 %
Predicción 10 Pasos (Viento Conocido)	0.2833	91.9641 %
Predicción 10 Pasos (Viento Promedio)	0.8054	35.0327 %
Predicción N Pasos (Viento Conocido)	0.4786	77.3248 %
Predicción N Pasos (Viento Promedio)	0.7510	43.6625 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura 5.4.1 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.4.1: Predicciones modelo difuso Babushka obtenido por búsqueda exhaustiva.

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.

5.4.2. Modelo obtenido por análisis de sensibilidad

Generar todos los modelos resultantes de todas las combinaciones posibles de un conjunto de regresores puede resultar ser muy costoso desde el punto de vista computacional, por lo que, la misma manera que en el caso de los modelos ARX, se recurrió a una técnica de selección de regresores por análisis de sensibilidad para definir la estructura del modelo. Se utilizó la técnica presentada en la Sección 1.1.2.2.

Se evaluaron $N = 18$ modelos en total. A partir de los modelos obtenidos, se seleccionó el modelo con menor *error cuadrático medio* en la predicción a 1 paso. En (5.4.5) se describe el conjunto de regresores que forman el modelo que cumple el criterio de menor *error cuadrático medio* entre todos

los modelos calculados, además del número de clusters C correspondiente al modelo.

$$\begin{aligned}
 C &= 2 \\
 N_y &= 3 \\
 N_u &= \begin{bmatrix} 3 & 1 \end{bmatrix} \\
 N_d &= \begin{bmatrix} 1 & 2 \end{bmatrix}
 \end{aligned} \tag{5.4.5}$$

Como parámetro del clustering difuso se usó un índice de fusificación $m = 2.5$.

Las funciones de pertenencia obtenidas corresponden a gaussianas dobles, definidas por la Ecuación (5.4.6)

$$\mu_{A_{ij}}(x) = \begin{cases} e^{-\frac{(x-a_1)^2}{2 \cdot b_1}} & x < a_1 \\ 1 & a_1 < x < a_2, \\ e^{-\frac{(x-a_2)^2}{2 \cdot b_2}} & a_2 < x \end{cases} \tag{5.4.6}$$

en donde $\mu_{A_{ij}}$ corresponde a la función de pertenencia del conjunto difuso A_{ij} , asociado al regresor j de la regla i .

Las reglas tienen la siguiente forma:

$$R_i: \text{ If } X_1 \text{ is } A_{1i} \text{ and } \dots \text{ and } X_k \text{ is } A_{ki} \text{ then } Y_i = p_o^i + p_1^i \cdot X_1 + \dots + p_k^i \cdot X_k,$$

en donde:

X_1, \dots, X_k son las variables de entrada o premisas de las reglas.

A_{1i}, \dots, A_{ki} son los conjuntos difusos asociados a las variables de entrada.

Y_i es la salida de la regla i .

Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (5.4.7).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \tag{5.4.7}$$

En la función (5.4.7), w_r corresponde al grado de activación de la regla r . En (5.4.8) se muestra la definición de w_r .


$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (5.4.8)$$

En la Tabla 5.4.2 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro 5.4.2: Resultados modelo difuso Babuska obtenido por análisis de sensibilidad.

Prueba	ECM	VAF
Predicción 1 Paso	0.1639	97.3138 %
Predicción 10 Pasos (Viento Conocido)	0.7107	49.4121 %
Predicción 10 Pasos (Viento Promedio)	0.7842	38.3921 %
Predicción N Pasos (Viento Conocido)	0.9226	14.8826 %
Predicción N Pasos (Viento Promedio)	0.7608	42.1098 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura 5.4.2 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.4.2: Predicciones modelo difuso Babushka obtenido por análisis de sensibilidad.

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.

5.5. Modelo obtenido a partir de nuevo algoritmo (cálculo de parámetros de las consecuencias mediante mínimos cuadrados)

Debido al tiempo computacional que emplea generar un modelo utilizando el nuevo método de selección de reglas por GA y cálculo de parámetros de las consecuencias por minimización de mínimos cuadrados es de aproximadamente 10 minutos, se decidió utilizar una base de regresores parecida a la óptima obtenida por búsqueda exhaustiva para los modelos ARX y difusos encontrados anteriormente.

5.5.1. Modelo obtenido por base de regresores fija

En (5.5.1) se muestra la base de regresores utilizada.

$$\begin{aligned}
 C &= 2 \\
 N_y &= 1 \\
 N_u &= \begin{bmatrix} 3 & 1 \end{bmatrix} \\
 N_d &= \begin{bmatrix} 1 & 3 \end{bmatrix}
 \end{aligned} \tag{5.5.1}$$

Como parámetro del clustering difuso se usó un índice de fusificación $m = 2.5$.

Las funciones de pertenencia obtenidas corresponden a sigmoidales, definidas por la Ecuación (5.5.2)

$$\mu_{A_{ij}}(x) = \frac{1}{1 + e^{-a \cdot (x-b)}}, \tag{5.5.2}$$

en donde $\mu_{A_{ij}}$ corresponde a la función de pertenencia del conjunto difuso A_{ij} , asociado al regresor j de la regla i .

Las reglas tienen la siguiente forma:

$$R_i: \text{ If } X_1 \text{ is } A_{1i} \text{ and } \dots \text{ and } X_k \text{ is } A_{ki} \text{ then } Y_i = p_o^i + p_1^i \cdot X_1 + \dots + p_k^i \cdot X_k,$$

en donde:

X_1, \dots, X_k son las variables de entrada o premisas de las reglas.

A_{1i}, \dots, A_{ki} son los conjuntos difusos asociados a las variables de entrada.

Y_i es la salida de la regla i .

Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (5.5.3).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \tag{5.5.3}$$

En la función (5.5.3), w_r corresponde al grado de activación de la regla r . En (5.5.4) se muestra la definición de w_r .


$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (5.5.4)$$

En la Tabla 5.5.1 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro 5.5.1: Predicciones modelo difuso obtenido por nuevo método. Cálculo de parámetros de las consecuencias por mínimos cuadrados.

Prueba	ECM	VAF
Predicción 1 Paso	0.2165	95.4569 %
Predicción 10 Pasos (Viento Conocido)	1.1693	-26.6477 %
Predicción 10 Pasos (Viento Promedio)	1.1222	-18.7666 %
Predicción N Pasos (Viento Conocido)	2.8729	-696.1592 %
Predicción N Pasos (Viento Promedio)	2.7823	-650.7001 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura 5.5.1 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.5.1: Predicciones modelo difuso obtenido por nuevo método. Cálculo de parámetros de las consecuencias por mínimos cuadrados.

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.

5.6. Modelo obtenido a partir de nuevo algoritmo (cálculo de parámetros de las consecuencias mediante PSO)

Con los recursos computacionales disponibles, identificar un modelo difuso con el nuevo método de identificación tarda aproximadamente 3 horas. Bajo esta condición, realizar una búsqueda exhaustiva de la base de regresores resulta infactible. Es necesario recurrir a otros métodos de selección de estructura del modelo.

Se usaron dos métodos:

1. Se utilizó una base de regresores parecida a la óptima obtenida por búsqueda exhaustiva para

los modelos ARX y difusos encontrados anteriormente.

2. Se encontró una base de regresores usando análisis de sensibilidad sobre el nuevo algoritmo.

A continuación se muestran los resultados obtenidos mediante ambos métodos.

5.6.1. Modelos obtenidos por base de regresores fija

En (5.6.2) se muestra la base de regresores utilizada.

$$C = 2$$

$$N_y = 1 \tag{5.6.1}$$

$$N_u = \begin{bmatrix} 3 & 1 \end{bmatrix} \tag{5.6.2}$$

$$N_d = \begin{bmatrix} 1 & 3 \end{bmatrix}$$

Basado en la experiencia obtenida por la identificación difusa realizada con el toolbox de Babuska, se decidió utilizar $C = 2$ clusters con un índice de fusificación $m = 2.5$. Los clusters obtenidos se aproximaron por funciones sigmoideas.

Las funciones de pertenencia obtenidas corresponden a sigmoideas, definidas por la Ecuación (5.6.3)

$$\mu_{A_{ij}}(x) = \frac{1}{1 + e^{-a \cdot (x-b)}}, \tag{5.6.3}$$

en donde $\mu_{A_{ij}}$ corresponde a la función de pertenencia del conjunto difuso A_{ij} , asociado al regresor j de la regla i .

Las reglas tienen la siguiente forma:

$$R_i: \text{ If } X_1 \text{ is } A_{1i} \text{ and } \dots \text{ and } X_k \text{ is } A_{ki} \text{ then } Y_i = p_o^i + p_1^i \cdot X_1 + \dots + p_k^i \cdot X_k,$$

en donde:

X_1, \dots, X_k son las variables de entrada o premisas de las reglas.

A_{1i}, \dots, A_{ki} son los conjuntos difusos asociados a las variables de entrada.

Y_i es la salida de la regla i .

Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (5.6.4).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (5.6.4)$$

En la función (5.6.4), w_r corresponde al grado de activación de la regla r . En (5.6.5) se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (5.6.5)$$

Debido a la naturaleza aleatoria del método, no siempre se obtienen los mismos resultados al realizar la identificación. Por esa razón se muestran los resultados de las simulaciones de cuatro modelos seleccionados.


5.6.1.1. Resultados Modelo A. Mejor modelo obtenido en la predicción a 1 paso.

En la Tabla 5.6.1 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro 5.6.1: Resultados modelo difuso obtenido por nuevo método (mejor modelo predicción a 1 paso).

Prueba	ECM	VAF
Predicción 1 Paso	0.1121	98.7428 %
Predicción 10 Pasos (Viento Conocido)	0.4480	79.8953 %
Predicción 10 Pasos (Viento Promedio)	0.4513	79.6132 %
Predicción N Pasos (Viento Conocido)	1.3528	-82.1642 %
Predicción N Pasos (Viento Promedio)	1.3491	-81.2267 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura 5.6.1 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.6.1: Predicciones modelo difuso obtenido por nuevo método (mejor modelo predicción a 1 paso).

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.


5.6.1.2. Resultados Modelo B. Mejor modelo obtenido en la predicción a 10 pasos con viento conocido.

En la Tabla 5.6.2 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro 5.6.2: Resultados modelo difuso obtenido por nuevo método (mejor modelo predicción a 10 pasos).

Prueba	ECM	VAF
Predicción 1 Paso	0.1372	98.1207 %
Predicción 10 Pasos (Viento Conocido)	0.2755	92.5603 %
Predicción 10 Pasos (Viento Promedio)	0.7331	46.5181 %
Predicción N Pasos (Viento Conocido)	0.6758	59.1393 %
Predicción N Pasos (Viento Promedio)	0.9733	14.4593 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura 5.6.2 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.6.2: Predicciones modelo difuso obtenido por nuevo método (mejor modelo predicción a 10 pasos).

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.


5.6.1.3. Resultados Modelo C. Mejor modelo obtenido en la predicción a 10 pasos con viento promedio.

En la Tabla 5.6.3 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro 5.6.3: Resultados modelo difuso obtenido por nuevo método (mejor modelo predicción a 10 pasos, viento promedio).

Prueba	ECM	VAF
Predicción 1 Paso	0.1121	98.7428 %
Predicción 10 Pasos (Viento Conocido)	0.4480	79.8953 %
Predicción 10 Pasos (Viento Promedio)	0.4513	79.6132 %
Predicción N Pasos (Viento Conocido)	1.3528	-82.1642 %
Predicción N Pasos (Viento Promedio)	1.3491	-81.2267 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura 5.6.3 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.6.3: Predicciones modelo difuso obtenido por nuevo método (mejor modelo predicción a 10 pasos, viento promedio).

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.


5.6.1.4. Resultados Modelo D. Mejor modelo obtenido en la predicción a N pasos con viento conocido.

En la Tabla 5.6.4 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro 5.6.4: Resultados modelo difuso obtenido por nuevo método (mejor modelo predicción a N pasos).

Prueba	ECM	VAF
Predicción 1 Paso	0.1317	98.2669 %
Predicción 10 Pasos (Viento Conocido)	0.3546	87.4843 %
Predicción 10 Pasos (Viento Promedio)	0.6417	59.7951 %
Predicción N Pasos (Viento Conocido)	0.6476	60.0552 %
Predicción N Pasos (Viento Promedio)	0.8331	40.5174 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura 5.6.4 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.6.4: Predicciones modelo difuso obtenido por nuevo método (mejor modelo predicción a N pasos).

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.

5.6.2. Modelos obtenidos por análisis de sensibilidad

Al igual que con los modelos difusos obtenidos con el toolbox de Babuska, también se obtuvieron modelos difusos con el nuevo método usando análisis de sensibilidad.

El procedimiento utilizado es el mismo usado en la Sección 1.1.2.2, pero se usó el nuevo método de identificación en vez del método de Babuska.

Se realizaron 10 réplicas del método de identificación usando análisis de sensibilidad para seleccionar los regresores. El método está basado en algoritmos evolutivos cuyas condiciones iniciales son aleatorias, por lo que en cada réplica se obtuvieron resultados diferentes.

Se seleccionó el mejor modelo. El modelo seleccionados corresponde al que presentó menor *error cuadrático medio* en cada una de las pruebas realizadas.

En (5.6.6) se muestra la base de regresores obtenida.

$$\begin{aligned}
 C &= 2 \\
 N_y &= 2 \\
 N_u &= \begin{bmatrix} 1 & 1 \end{bmatrix} \\
 N_d &= \begin{bmatrix} 2 & 2 \end{bmatrix}
 \end{aligned} \tag{5.6.6}$$

Las funciones de pertenencia obtenidas corresponden a sigmoideas, definidas por la Ecuación (5.6.7)

$$\mu_{A_{ij}}(x) = \frac{1}{1 + e^{-a \cdot (x-b)}}, \tag{5.6.7}$$

en donde $\mu_{A_{ij}}$ corresponde a la función de pertenencia del conjunto difuso A_{ij} , asociado al regresor j de la regla i .

Las reglas tienen la siguiente forma:

$$R_i: \text{ If } X_1 \text{ is } A_{1i} \text{ and } \dots \text{ and } X_k \text{ is } A_{ki} \text{ then } Y_i = p_o^i + p_1^i \cdot X_1 + \dots + p_k^i \cdot X_k,$$

en donde:

X_1, \dots, X_k son las variables de entrada o premisas de las reglas.

A_{1i}, \dots, A_{ki} son los conjuntos difusos asociados a las variables de entrada.

Y_i es la salida de la regla i .

Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (5.6.8).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (5.6.8)$$

En la función (5.6.8), w_r corresponde al grado de activación de la regla r . En (5.6.9) se muestra la definición de w_r .

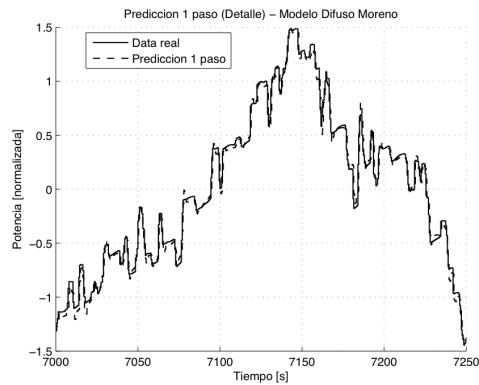
$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (5.6.9)$$

Resultados En la Tabla 5.6.5 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro 5.6.5: Resultados modelo difuso obtenido por nuevo método (análisis de sensibilidad).

Prueba	ECM	VAF
Predicción 1 Paso	0.1117	98.7517 %
Predicción 10 Pasos (Viento Conocido)	0.3287	89.1839 %
Predicción 10 Pasos (Viento Promedio)	0.3661	86.5703 %
Predicción N Pasos (Viento Conocido)	0.9185	15.9336 %
Predicción N Pasos (Viento Promedio)	0.9185	13.1466 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura 5.6.5 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura 5.6.5: Predicciones modelo difuso obtenido por nuevo método, obtenido por análisis de sensibilidad. Cálculo de parámetros de las consecuencias por PSO.

En la sección 5.7 se presentan algunos comentarios acerca de los resultados obtenidos.

5.7. Resultados

5.7.1. Tiempos computacionales

En la Tabla 5.7.1 se presentan los tiempos computacionales que involucra la ejecución de cada uno de los métodos de identificación empleados. Los procedimientos se realizaron corriendo Matlab en un computador Apple MacBook Pro con un procesador Intel Core i5 de 2.4 GHz y 4 GB de memoria RAM. El sistema operativo utilizado fue Mac OS X versión 10.6.

Cuadro 5.7.1: Tiempos computacionales que involucra la ejecución de cada uno de los métodos de identificación.

Método de identificación	Tiempo de ejecución [s]
ARX	0.0326
Babuska	2.5902
Nuevo método (mínimos cuadrados)	1381.7
Nuevo método (PSO, 30 iteraciones)	5960.5

Se puede apreciar que el nuevo método es un 2300 % más lento que el método desarrollado por Babuska.

5.7.2. Resultados de modelos obtenidos por búsqueda exhaustiva

5.7.2.1. Predicción a 1 Paso

En la Tabla 5.7.6 se muestran los resultados de la predicción a 1 paso realizada con los distintos modelos.

Cuadro 5.7.2: Predicciones a 1 Paso - Modelos obtenidos por búsqueda exhaustiva

Modelo	ECM	VAF
ARX	0.1068	98.8593 %
Babuska	0.1612	97.4008 %
Nuevo método (Mínimos cuadrados)	0.2165	95.4569 %
Nuevo método (PSO) - Modelo A	0.1121	98.7428 %
Nuevo método (PSO) - Modelo B	0.1372	98.1207 %
Nuevo método (PSO) - Modelo C	0.1121	98.7428 %
Nuevo método (PSO) - Modelo D	0.1317	98.2669 %

En la Figura 5.7.1 se compara el índice VAF de las predicciones a 1 paso obtenidas a partir de cada modelo.




Figura 5.7.1: Resultados predicción a 1 paso

En la Tabla 5.7.6 es posible observar que el modelo que presenta menor error cuadrático medio en la predicción a 1 paso es el modelo ARX. En segundo lugar se encuentra el Modelo Difuso A, seguido del Modelo Difuso C. Recién en cuarto lugar se encuentra el modelo difuso obtenido mediante el toolbox de Babuska. En último lugar se encuentra el modelo difuso obtenido mediante el nuevo método de identificación, calculando los parámetros de las consecuencias mediante minimización de mínimos cuadrados.

Llama la atención que, dada la naturaleza no lineal del sistema que se quiere identificar, el modelo con mejor desempeño en la predicción a 1 paso sea lineal. Esto se debe a que la única forma de tomar datos en este sistema es en lazo cerrado, lo que obliga a que el sistema tienda a permanecer en cierto punto de operación, salvo perturbaciones.

5.7.2.2. Predicción a 10 Pasos

En la Tabla 5.7.4 se muestran los resultados de la predicción a 10 pasos realizada con los distintos modelos.

Cuadro 5.7.3: Predicciones a 10 Pasos - Modelos obtenidos por búsqueda exhaustiva

Modelo	ECM	VAF
ARX	0.2829	91.9849 %
Babuska	0.2833	91.9641 %
Nuevo método (Mínimos cuadrados)	1.1693	-266477 %
Nuevo método (PSO) - Modelo A	0.4480	79.8953 %
Nuevo método (PSO) - Modelo B	0.2755	92.5603 %
Nuevo método (PSO) - Modelo C	0.4480	79.8953 %
Nuevo método (PSO) - Modelo D	0.3546	87.4843 %

En la Figura 5.7.2 se compara el índice VAF de las predicciones a 10 pasos obtenidas a partir de cada modelo.




Figura 5.7.2: Resultados predicción a 10 pasos

En la tabla 5.7.4 se puede observar que tanto el Modelo B, como los modelos ARX y aquel obtenido mediante el toolbox de Babuska tuvieron un desempeño similar. El modelo obtenido mediante mínimos cuadrados no arrojó resultados utilizables.

5.7.2.3. Predicción a 10 Pasos (Velocidad de viento promedio)

En la Tabla 5.7.4 se muestran los resultados de la predicción a 10 pasos, con velocidad de viento promedio, realizada con los distintos modelos.

Cuadro 5.7.4: Predicciones a 10 Pasos (Velocidad de viento promedio) - Modelos obtenidos por búsqueda exhaustiva

Modelo	ECM	VAF
ARX	0.5529	69.3757 %
Babuska	0.8054	35.0327 %
Nuevo método (Mínimos cuadrados)	1.1222	-18.7666 %
Nuevo método (PSO) - Modelo A	0.4480	79.8953 %
Nuevo método (PSO) - Modelo B	0.7331	46.5181 %
Nuevo método (PSO) - Modelo C	0.4513	79.6132 %
Nuevo método (PSO) - Modelo D	0.6417	59.7951 %

En la Figura 5.7.3 se compara el índice VAF de las predicciones a 10 pasos, con velocidad de viento promedio, obtenidas a partir de cada modelo.




Figura 5.7.3: Resultados predicción a 10 pasos (Velocidad del viento promedio)

En la Tabla 5.7.4 se puede observar que los Modelos C y A presentan los índices de desempeño de mejor calidad. En tercer lugar aparece el modelo ARX y en cuarto lugar, con un desempeño bastante bajo en comparación con los otros modelos, aparece el modelo obtenido mediante el toolbox de Babuska. En este caso el modelo calculado con mínimos cuadrados tampoco es utilizable.

Este caso de análisis es notable, porque para obtener los resultados se trabajó con un predictor de viento muy rudimentario. Éste consistió en utilizar la velocidad promedio del viento para realizar predicciones futuras. Este caso sería el que más se acerca a la realidad en la utilización de un sistema de control predictivo.

5.7.2.4. Predicción a N Pasos

En la Tabla 5.7.9 se muestran los resultados de la predicción a N pasos realizada con los distintos modelos.

Cuadro 5.7.5: Predicciones a N Pasos - Modelos obtenidos por búsqueda exhaustiva

Modelo	ECM	VAF
ARX	0.5039	74.6055 %
Babuska	0.4786	77.3248 %
Nuevo método (Mínimos cuadrados)	2.8729	-696.1592 %
Nuevo método (PSO) - Modelo A	1.3528	-82.1642 %
Nuevo método (PSO) - Modelo B	0.6758	59.1393 %
Nuevo método (PSO) - Modelo C	1.3528	-82.1642 %
Nuevo método (PSO) - Modelo D	0.6476	60.0552 %

En la Figura 5.7.4 se compara el índice VAF de las predicciones a N pasos obtenidas a partir de cada modelo.




Figura 5.7.4: Resultados predicción a N pasos

En la Tabla 5.7.9 se puede observar que en la predicción a N pasos el modelo que presenta mejor desempeño es el modelo obtenido mediante el toolbox de Babuska. En segundo lugar aparece el modelo ARX y en tercer y cuarto lugar aparecen los modelos D y B, respectivamente.

5.7.3. Resultados de modelos obtenidos por análisis de sensibilidad

5.7.3.1. Predicción a 1 Paso

En la Tabla 5.7.6 se muestran los resultados de la predicción a 1 paso realizada con los distintos modelos.

Cuadro 5.7.6: Predicciones a 1 Paso - Modelos obtenidos por búsqueda análisis de sensibilidad

Modelo	ECM	VAF
ARX	0.1070	98.8553 %
Babuska	0.1639	97.3138 %
Nuevo método (PSO)	0.1117	98.7517 %

En la Figura 5.7.5 se compara el índice VAF de las predicciones a 1 paso obtenidas a partir de cada modelo.




Figura 5.7.5: Resultados predicción a 1 paso

En la Tabla 5.7.6 se puede observar que los resultados de las predicciones a 1 paso, calculadas a partir de modelos obtenidos mediante análisis de sensibilidad, presentan resultados similares a las predicciones a 1 paso obtenidas mediante los modelos encontrados por búsqueda exhaustiva. En este caso el modelo ARX fue el de mejor desempeño, seguido del modelo PSO y finalmente el con peor desempeño fue el modelo obtenido mediante el toolbox de Babuska.

5.7.3.2. Predicción a 10 Pasos

En la Tabla 5.7.7 se muestran los resultados de la predicción a 10 pasos realizada con los distintos modelos.

Cuadro 5.7.7: Predicciones a 10 Pasos - Modelos obtenidos por búsqueda análisis de sensibilidad

Modelo	ECM	VAF
ARX	0.6120	62.4960 %
Babuska	0.7107	49.4121 %
Nuevo método (PSO)	0.3287	89.1839 %

En la Figura 5.7.6 se compara el índice VAF de las predicciones a 10 pasos obtenidas a partir de cada modelo.




Figura 5.7.6: Resultados predicción a 10 pasos

En la Tabla 5.7.7 se puede observar que el modelo PSO lidera considerablemente en los índices de desempeño. Desde atrás lo siguen los modelos ARX y Babuska. Llama la atención que el modelo PSO presenta un índice de desempeño bastante más alto que el modelo obtenido mediante el nuevo método, pero con base de regresores fija. El desempeño obtenido es comparable al desempeño de la predicción a 10 pasos de los modelos Babuska y ARX obtenidos mediante búsqueda exhaustiva.

5.7.3.3. Predicción a 10 Pasos (Velocidad de viento promedio)

En la Tabla 5.7.8 se muestran los resultados de la predicción a 10 pasos, con velocidad de viento promedio, realizada con los distintos modelos.

Cuadro 5.7.8: Predicciones a 10 Pasos (Velocidad de viento promedio) - Modelos obtenidos por búsqueda análisis de sensibilidad

Modelo	ECM	VAF
ARX	0.6375	59.2909 %
Babushka	0.7842	38.3921 %
Nuevo método (PSO)	0.3661	86.5703 %

En la Figura 5.7.7 se compara el índice VAF de las predicciones a 10 pasos, con velocidad de viento promedio, obtenidas a partir de cada modelo.




Figura 5.7.7: Resultados predicción a 10 pasos (Velocidad del viento promedio)

En la Tabla 5.7.8 se puede observar que la predicción a 10 pasos con viento promedio de mejor calidad, es aquella obtenida mediante el modelo PSO. Incluso su calidad la mejor al comparar los datos con los de la tabla 5.7.4, correspondiente a los modelos obtenidos por búsqueda exhaustiva. Este resultado es muy importante, porque es el que se asemeja más a una situación real de control predictivo.

5.7.3.4. Predicción a N Pasos

En la Tabla 5.7.9 se muestran los resultados de la predicción a N pasos realizada con los distintos modelos.

Cuadro 5.7.9: Predicciones a N Pasos - Modelos obtenidos por búsqueda análisis de sensibilidad

Modelo	ECM	VAF
ARX	0.5738	67.0800 %
Babuska	0.9226	14.8826 %
Nuevo método (PSO)	0.9185	15.9336 %

En la Figura 5.7.8 se compara el índice VAF de las predicciones a N pasos obtenidas a partir de cada modelo.




Figura 5.7.8: Resultados predicción a N pasos

En la Tabla 5.7.9 se puede observar que la mejor predicción a N pasos es la obtenida con el modelo ARX. En segundo lugar se ubica la obtenida con el modelo PSO y en tercer lugar se ubica la obtenida mediante el modelo calculado con el toolbox de Babuska. Las predicciones a N pasos fueron deficientes en comparación con las obtenidas con los modelos calculados a partir de las otras metodologías, porque los modelos obtenidos no resultaron ser globalmente estables.

Capítulo 6

Conclusiones

Se mejoró el desarrollo de un simulador del modelo matemático de un aerogenerador. El modelo está basado en ecuaciones diferenciales ordinarias. La modelación del aerogenerador fue obtenida a partir de la literatura existente. El simulador fue utilizado para tomar datos de entrada y salida para posteriormente encontrar modelos de caja negra usando diferentes métodos de identificación. El simulador puede ser calibrado para representar a algún aerogenerador en particular y luego probar diseños de distintas estrategias de control sobre éste.

Se realizó una implementación computacional de las diferentes versiones del método de identificación difusa propuesto y, a partir de las implementaciones mencionadas y mediciones de las entradas y salidas, fue posible obtener modelos dinámicos difusos del aerogenerador simulado.

La versión del método que utiliza minimización de mínimos cuadrados para el cálculo de los parámetros de las premisas arrojó modelos de reglas inestables como resultado. Por esa razón, ninguno de los modelos obtenidos a partir de este método pudo ser utilizado para hacer predicciones más allá de 1 paso.

Por otra parte, la versión del método que utiliza PSO para calcular los parámetros de las premisas funcionó satisfactoriamente, arrojando modelos con consecuencias de las reglas estables. Por consiguiente, si fue posible obtener predicciones a más de 1 paso a partir de los modelos obtenidos con esta metodología. La estabilidad de las reglas de este modelo se debe a que la programación de PSO para la obtención de los parámetros de las consecuencias obliga a que cada uno de los parámetros pertenezca al intervalo $[-1, 1]$.

A partir de esta misma versión del mismo método, en las predicciones a 1 y 10 pasos realizadas con modelos con una base de regresores fija, se lograron obtener modelos de rendimiento mejor o comparable al los obtenidos con la búsqueda exhaustiva de modelos ARX o difusos calculados con el toolbox de Babuska. Las predicciones a N pasos fueron deficientes en comparación con las obtenidas con los modelos calculados a partir de las otras metodologías, porque los modelos obtenidos no resultaron ser globalmente estables. El nuevo método podría extenderse incorporando restricciones que obliguen a que los modelos candidatos sean globalmente estables y así lograr obtener predicciones a N pasos de mejor calidad.

Se obtuvieron muy buenos resultados en las predicciones a 1 y 10 pasos con el nuevo método, combinado con análisis de sensibilidad. Los resultados fueron superiores que los obtenidos por la búsqueda por análisis de sensibilidad de modelos ARX o difusos calculados con el toolbox de Babuska. No se usó el método de búsqueda exhaustiva para poner a prueba el nuevo método de identificación, por el alto costo computacional que una prueba de esa magnitud involucraría. A partir de los resultados de las pruebas por análisis de sensibilidad sería interesante realizar una búsqueda exhaustiva de la base de regresores con el nuevo método, para encontrar modelos incluso de mejor calidad.

Una desventaja del nuevo método es su lentitud y uso intensivo de memoria RAM. Para obtener un modelo de calidad se deben invertir cerca de 2 horas con los recursos computacionales disponibles, mientras que los métodos ARX y Babuska logran obtener modelos en unos cuantos segundos. El uso intensivo de la memoria RAM se debe a que es necesario almacenar las matrices de datos y pasos intermedios para cada uno de los individuos de la población GA y para cada una de las partículas PSO asociadas a cada individuo, por lo que se está ocupando la cantidad de memoria equivalente a decenas de identificaciones simultáneas calculadas con métodos tradicionales.

Como trabajo futuro, además de la incorporación de restricciones que aseguren las estabilidad global de los sistemas, se podrían modificar las funciones de *fitness* para realizar optimizaciones bajo otros criterios. Por ejemplo se puede modificar la función de *fitness* por el error cuadrático medio de una predicción a más de 1 paso, que fue la que se utilizó en este trabajo.

Bibliografía

- [1] Angeline, P. (1998). Evolutionary optimization versus particle swarm optimization: Philosophy and performance differences. *Evolutionary Programming VII*, 601-610.
- [2] Åström, K. J., Wittenmark, B. (1994). *Adaptive Control (Second Edition)*. Addison Wesley.
- [3] Babuska, R. (1998) *Fuzzy Modeling for Control*. Kluwer Academic Publishers, Boston, 1998
- [4] Back. T., Fogel, D., Michalewicz, Z. (1997). *Handbook on Evolutionary Computacion*. IOP Publishing Ltd and Oxford University Press.
- [5] J. Banks - J. S. Carson - B. Nelson (2006): *Discrete-Event System Simulation*, Ed. Prentice Hall, Ney Jersey.
- [6] Duarte, M (2006): *Apuntes de Clases del Curso EL32D Análisis y Modelación de Sistemas Dinámicos*, Departamento de Ingeniería Eléctrica, Universidad de Chile.
- [7] Eberhart, R., Kennedy, J. (1995). A new optimizer using particle swarm theory. *Proceedings 6th Int. Symp. Micromachine Human Sci* 1, 39 – 43.
- [8] Eberhart, R., Shi, Y. (1998). Comparison between genetic algorithms and particle swarm optimization. *Proc. 7th Conf. Evol. Program*, 1447, 611-616.
- [9] Espinosa J., Vandewalle J., Wertz V. (2005). *Fuzzy logic, identification and predictive control*, *Advances in industrial control*, Springer, 2005, 263 p. ISBN:1852338288
- [10] European Wind Energy Association (2009). *Wind Energy - The Facts*.
http://www.ewea.org/fileadmin/ewea_documents/documents/publications/WETF/1565_ExSum_ENG.p

- [11] Fernández Díez, P. (2008). Energía Eólica. Departamento de Ingeniería Eléctrica y Energética, Universidad de Cantabria, España. <http://es.libros.redsauce.net/index.php?pageID=16>
- [12] Goldberg, D. (1989). Genetic Algorithms in search, optimization and machine learning. Addison-Wesley Publishing Corporation, Inc.
- [13] González, G (2008): Apuntes de Clases del Curso EM717 Identificación Para El Control de Sistemas, Departamento de Ingeniería Eléctrica, Universidad de Chile.
- [14] Holland, J. (1975). Adaptation in Natural and Artificial Systems. University of Michigan Press.
- [15] Iov, F., Hansen A. D., Sørensen, P., Blaabjerg, F. (2004). Wind Turbine Blockset in Matlab/- Simulink, Aalborg University, Denmark.
- [16] Izquierdo, L – Galán J. M. – Santos, J – Del Olmo, R (2008): Modelado de sistemas complejos mediante simulación basada en agentes y mediante dinámica de sistemas. EMPIRIA. Revista de Metodología de Ciencias Sociales. N.o 16, julio-diciembre, 2008, pp. 85-112. ISSN: 1139-5737
- [17] Kennedy, J and Erberhart, R. (2001). Swarm Intelligence. Morgan Kaufmann Publishers, Inc., San Francisco, CA.
- [18] Molenaar, D. (2003). Cost-effective design and operation of variable speed wind turbines, DUP Science, Delft University Press, The Netherlands.
- [19] Muñoz, D. (2010). Diseño y Evaluación de Algoritmos Evolutivos Para Estrategias de Control Predictivo Híbrido No Lineal. Universidad de Chile.
- [20] Nedjah, N., Macedo Mourelle, L. (2006). Swarm Intelligent Systems. Studies in Computational Intelligence. Vol. 26, Springer –Verlag.
- [21] Ororz , J., Jacobson, S. (2002). Analysis of static simulated annealing algorithms. Journal of Optimization Theory and Applications 115(1), 165-182.
- [22] Papathanassiou, S. A. (1997). Models for Variable Speed Wind Turbines. School of Electrical and Computer Engineering, National Technical University of Athens, Greece.
- [23] Perros, H (2009): Computer Science Department, North Carolina State University at Raleigh, North Carolina, <http://www4.ncsu.edu/~hp//simulation.pdf>

- [24] Shi, Y., Eberhart, R. (1999). Empirical study of particle swarm optimization. Proceedings of the 1999 Congress on Evolutionary Computation, 101-106.
- [25] Sloomweg, J. G., Polinder, H., Kling, W. L. (2001). Dynamic Modelling of a Wind Turbine with Doubly Fed Induction Generator. IEEE Power Engineering Society Summer Meeting, 2001, pp. 644-649.
- [26] Soares, O., Gonçalves, H., Martins, A., Carvalho, A. (2010). Nonlinear control of the doubly-fed induction generator in wind Power systems. *Renewable Energy* 35 (2010) 1662–1670
- [27] Sørensen, P., Hansen, A.D., Rosas, P.A.C. (2002). Wind models for simulation of power fluctuations from wind farms, *Journal of Wind Engineering*, 90, 2002, pp. 1381-1402;
- [28] U.S. Department of Energy (2008). 20% Wind Energy by 2030 - Increasing Energy's Contribution to U.S. Electricity Supply. http://www.20percentwind.org/20percent_wind_energy_report_revOct08.pdf
- [29] Woolfson M.M. - Pert G.J. (1999): *An Introduction To Computer Simulation*, Oxford University Press, Oxford.
- [30] Zadeh, L. A. (1965). Fuzzy Sets. *Information and Control*, vol.8, pp 338-353, 1965.

Apéndice A

Estructura de los modelos obtenidos

A.1. Modelo Babuska

A.1.1. Modelo obtenido por búsqueda exhaustiva

A continuación se muestra en detalle el modelo óptimo obtenido.

Base de Regresores

$$\begin{aligned} C &= 2 \\ N_y &= 1 \\ N_u &= \begin{bmatrix} 3 & 1 \end{bmatrix} \\ N_d &= \begin{bmatrix} 1 & 2 \end{bmatrix} \end{aligned} \tag{A.1.1}$$

Funciones de Pertenencia A continuación se muestran las funciones de pertenencia de los conjuntos difusos asociados a cada regla y regresor. El toolbox de Babuska genera clusters formados por dos gaussianas, como se indica en las funciones que se muestran a continuación.

■ Regla 1

- Conjunto A_{11} (regresor $P(k-1)$)

$$\mu_{A_{11}}(x) = \begin{cases} e^{\frac{-(x+5.178)^2}{2 \cdot 10^{-20}}} & x < -5.178 \\ 1 & -5.177 < x < -0.074 \\ e^{\frac{-(x+0.074)^2}{5.404}} & -0.074 < x \end{cases} \quad (\text{A.1.2})$$

- Conjunto A_{12} (regresor $v(k-1)$)

$$\mu_{A_{12}}(x) = \begin{cases} e^{\frac{-(x-1.051)^2}{3.6396}} & x < 1.051 \\ 1 & 1.051 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.3})$$

- Conjunto A_{13} (regresor $v(k-2)$)

$$\mu_{A_{13}}(x) = \begin{cases} e^{\frac{-(x+0.048)^2}{0.988}} & x < -0.048 \\ 1 & -0.048 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.4})$$

- Conjunto A_{14} (regresor $v(k-3)$)

$$\mu_{A_{14}}(x) = \begin{cases} e^{\frac{-(x+0.169)^2}{0.258}} & x < -0.169 \\ 1 & -0.169 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.5})$$

- Conjunto A_{15} (regresor $\theta(k-2)$)

$$\mu_{A_{15}}(x) = \begin{cases} e^{\frac{-(x-1.7)^2}{11.9815}} & x < 1.7 \\ 1 & 1.7 < x < 7.263 \\ e^{\frac{-(x-7.262)^2}{2 \cdot 10^{-20}}} & 7.263 < x \end{cases} \quad (\text{A.1.6})$$

▪ Regla 2

- Conjunto A_{21} (regresor $P(k-1)$)

$$\mu_{A_{21}}(x) = \begin{cases} e^{-\frac{(x-0.6)^2}{12}} & x < 0.6 \\ 1 & 0.6 < x < 5.564 \\ e^{-\frac{(x-5.564)^2}{2 \cdot 10^{-20}}} & 5.564 < x \end{cases} \quad (\text{A.1.7})$$

- Conjunto A_{22} (regresor $v(k-1)$)

$$\mu_{A_{22}}(x) = \begin{cases} e^{-\frac{(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ 1 & -5.856 < x < -0.542 \\ e^{-\frac{(x+0.542)^2}{6.95}} & -0.542 < x \end{cases} \quad (\text{A.1.8})$$

- Conjunto A_{23} (regresor $v(k-2)$)

$$\mu_{A_{23}}(x) = \begin{cases} e^{-\frac{(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ e^{-\frac{(x+0.586)^2}{6.29}} & -0.586 < x \end{cases} \quad (\text{A.1.9})$$


- Conjunto A_{24} (regresor $v(k-3)$)

$$\mu_{A_{24}}(x) = \begin{cases} e^{-\frac{(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ 1 & -5.856 < x < -0.505 \\ e^{-\frac{(x+0.505)^2}{5.498}} & -0.505 < x \end{cases} \quad (\text{A.1.10})$$


- Conjunto A_{25} (regresor $\theta(k-2)$)

$$\mu_{A_{25}}(x) = \begin{cases} e^{-\frac{(x+8.103)^2}{2 \cdot 10^{-20}}} & x < -8.103 \\ 1 & -8.103 < x < -0.577 \\ e^{-\frac{(x+0.577)^2}{7.984}} & -0.577 < x \end{cases} \quad (\text{A.1.11})$$


En la Figura A.1.1 se muestran los gráficos correspondientes a las funciones de pertenencia del modelo difuso.




(a) $P(k-1)$




(b) $v(k-1)$



(c) $v(k-2)$



(d) $v(k-3)$



(e) $\theta(k-2)$

Figura A.1.1: Funciones de pertenencia.

Base de Reglas El sistema está formado por una base de tres reglas formadas por antecedentes y consecuencias. Al tratarse de un sistema difuso de Takagi - Sugeno, las consecuencias de la base de reglas están formadas por funciones lineales. A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{11} and $v(k-1)$ is A_{12} and $v(k-2)$ is A_{13} and $v(k-3)$ is A_{14} and $\theta(k-2)$ is A_{15} then $P_1(k) = 0.972 \cdot P(k-1) - 0.675 \cdot v(k-1) + 0.409 \cdot v(k-2) + 0.1503 \cdot v(k-3) + 0.198 \cdot \theta(k-2) - 0.004$
2. If $P(k-1)$ is A_{21} and $v(k-1)$ is A_{22} and $v(k-2)$ is A_{23} and $v(k-3)$ is A_{24} and $\theta(k-2)$ is A_{25} then $P_2(k) = 0.953 \cdot P(k-1) - 0.996 \cdot v(k-1) + 0.591 \cdot v(k-2) + 0.257 \cdot v(k-3) + 0.17 \cdot \theta(k-2) - 0.027$

Función de Salida Dado que el modelo identificado es de Takagi - Sugeno, la salida del sistema está dada por la función (A.1.12).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.1.12})$$

En la función (A.1.12), w_r corresponde al grado de activación de la regla r . En (A.1.13) se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (\text{A.1.13})$$

A.1.2. Modelo obtenido por análisis de sensibilidad

A continuación se muestra en detalle el modelo óptimo obtenido.

Base de Regresores

$$\begin{aligned} C &= 2 \\ N_y &= 3 \\ N_u &= \begin{bmatrix} 3 & 1 \end{bmatrix} \\ N_d &= \begin{bmatrix} 1 & 2 \end{bmatrix} \end{aligned} \quad (\text{A.1.14})$$

Funciones de Pertenencia A continuación se muestran las funciones de pertenencia de los conjuntos difusos asociados a cada regla y regresor. El toolbox de Babuska genera clusters formados por dos gaussianas, como se indica en las funciones que se muestran a continuación.

■ Regla 1

- Conjunto A_{11} (regresor $P(k-1)$)

$$\mu_{A_{11}}(x) = \begin{cases} e^{\frac{-(x+5.178)^2}{2 \cdot 10^{-20}}} & x < -5.178 \\ 1 & -5.177 < x < 5.564 \\ e^{\frac{-(x-5.564)^2}{2 \cdot 10^{-20}}} & 5.564 < x \end{cases} \quad (\text{A.1.15})$$

- Conjunto A_{12} (regresor $P(k-2)$)

$$\mu_{A_{12}}(x) = \begin{cases} e^{\frac{-(x+5.178)^2}{2 \cdot 10^{-20}}} & x < -5.178 \\ 1 & -5.178 < x < 5.564 \\ e^{\frac{-(x-5.564)^2}{2 \cdot 10^{-20}}} & 5.564 < x \end{cases} \quad (\text{A.1.16})$$

- Conjunto A_{13} (regresor $P(k-3)$)

$$\mu_{A_{13}}(x) = \begin{cases} e^{\frac{-(x+5.178)^2}{2 \cdot 10^{-20}}} & x < -5.178 \\ 1 & -5.178 < x < 5.564 \\ e^{\frac{-(x-5.564)^2}{2 \cdot 10^{-20}}} & 5.564 < x \end{cases} \quad (\text{A.1.17})$$

- Conjunto A_{14} (regresor $v(k-1)$)

$$\mu_{A_{14}}(x) = \begin{cases} e^{\frac{-(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ 1 & -5.856 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.18})$$

- Conjunto A_{15} (regresor $v(k-2)$)

$$\mu_{A_{15}}(x) = \begin{cases} e^{\frac{-(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ 1 & -5.856 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.19})$$

- Conjunto A_{16} (regresor $v(k-3)$)

$$\mu_{A_{16}}(x) = \begin{cases} e^{\frac{-(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ 1 & -5.856 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.20})$$

- Conjunto A_{17} (regresor $\theta(k-2)$)

$$\mu_{A_{17}}(x) = \begin{cases} e^{\frac{-(x+8.103)^2}{2 \cdot 10^{-20}}} & x < -8.103 \\ 1 & -8.103 < x < 7.263 \\ e^{\frac{-(x-7.262)^2}{2 \cdot 10^{-20}}} & 7.263 < x \end{cases} \quad (\text{A.1.21})$$

■ Regla 2

- Conjunto A_{21} (regresor $P(k-1)$)

$$\mu_{A_{21}}(x) = \begin{cases} e^{\frac{-(x+5.178)^2}{2 \cdot 10^{-20}}} & x < -5.178 \\ 1 & -5.178 < x < 5.564 \\ e^{\frac{-(x-5.564)^2}{2 \cdot 10^{-20}}} & 5.564 < x \end{cases} \quad (\text{A.1.22})$$

- Conjunto A_{22} (regresor $P(k-2)$)

$$\mu_{A_{22}}(x) = \begin{cases} e^{\frac{-(x+5.178)^2}{2 \cdot 10^{-20}}} & x < -5.178 \\ 1 & -5.178 < x < 5.564 \\ e^{\frac{-(x-5.564)^2}{2 \cdot 10^{-20}}} & 5.564 < x \end{cases} \quad (\text{A.1.23})$$

- Conjunto A_{23} (regresor $P(k-2)$)

$$\mu_{A_{23}}(x) = \begin{cases} e^{\frac{-(x+5.178)^2}{2 \cdot 10^{-20}}} & x < -5.178 \\ 1 & -5.178 < x < 5.564 \\ e^{\frac{-(x-5.564)^2}{2 \cdot 10^{-20}}} & 5.564 < x \end{cases} \quad (\text{A.1.24})$$

- Conjunto A_{24} (regresor $v(k-1)$)

$$\mu_{A_{24}}(x) = \begin{cases} e^{\frac{-(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ 1 & -5.856 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.25})$$

- Conjunto A_{25} (regresor $v(k-2)$)

$$\mu_{A_{25}}(x) = \begin{cases} e^{\frac{-(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ 1 & -5.856 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.26})$$


- Conjunto A_{26} (regresor $v(k-3)$)

$$\mu_{A_{26}}(x) = \begin{cases} e^{\frac{-(x+5.856)^2}{2 \cdot 10^{-20}}} & x < -5.856 \\ 1 & -5.856 < x < 6.38 \\ e^{\frac{-(x-6.38)^2}{2 \cdot 10^{-20}}} & 6.38 < x \end{cases} \quad (\text{A.1.27})$$


- Conjunto A_{27} (regresor $\theta(k-2)$)

$$\mu_{A_{27}}(x) = \begin{cases} e^{\frac{-(x+8.103)^2}{2 \cdot 10^{-20}}} & x < -8.103 \\ 1 & -8.103 < x < 7.263 \\ e^{\frac{-(x-7.262)^2}{2 \cdot 10^{-20}}} & 7.263 < x \end{cases} \quad (\text{A.1.28})$$


En la Figura A.1.2 se muestran los gráficos correspondientes a las funciones de pertenencia del modelo difuso.




(a) $P(k-1)$




(b) $P(k-2)$




(c) $P(k-3)$




(d) $v(k-1)$



(e) $v(k-2)$



(f) $v(k-3)$



(g) $\theta(k-3)$

Figura A.1.2: Funciones de pertenencia.

Base de Reglas El sistema está formado por una base de dos reglas formadas por antecedentes y consecuencias. Al tratarse de un sistema difuso de Takagi - Sugeno, las consecuencias de la base de reglas están formadas por funciones lineales. A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{11} and $P(k-2)$ is A_{12} and $P(k-3)$ is A_{13} and $v(k-1)$ is A_{14} and $v(k-2)$ is A_{15} and $v(k-3)$ is A_{16} and $\theta(k-2)$ is A_{17} then $P_1(k) = 2.0731 \cdot P(k-1) - 0.1078 \cdot P(k-2) - 0.0355 \cdot P(k-3) - 0.1521 \cdot v(k-3) + 0.3162 \cdot \theta(k-2) - 7.5433 \cdot 10^{-6}$
2. If $P(k-1)$ is A_{21} and $P(k-2)$ is A_{22} and $P(k-3)$ is A_{23} and $v(k-1)$ is A_{24} and $v(k-2)$ is A_{25} and $v(k-3)$ is A_{256} and $\theta(k-2)$ is A_{27} then $P_2(k) = -1.427 \cdot v(k-1) + 1.0568 \cdot v(k-2)$

Función de Salida Dado que el modelo identificado es de Takagi - Sugeno, la salida del sistema está dada por la función (A.1.29).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.1.29})$$

En la función (A.1.29), w_r corresponde al grado de activación de la regla r . En (A.1.30) se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (\text{A.1.30})$$

A.2. Modelo obtenido a partir de nuevo algoritmo (cálculo de parámetros de las consecuencias mediante mínimos cuadrados)

Debido al tiempo computacional que emplea generar un modelo utilizando el nuevo método de selección de reglas por GA y cálculo de parámetros de las consecuencias por minimización de mínimos cuadrados es de aproximadamente 10 minutos, se decidió utilizar una base de regresores parecida a la óptima obtenida por búsqueda exhaustiva para los modelos ARX y difusos encontrados anteriormente.

A.2.1. Modelo obtenido por base de regresores fija

Base de regresores.

$$\begin{aligned} C &= 2 \\ N_y &= 1 \\ N_u &= \begin{bmatrix} 3 & 1 \end{bmatrix} \\ N_d &= \begin{bmatrix} 1 & 3 \end{bmatrix} \end{aligned} \tag{A.2.1}$$

Como parámetro del clustering difuso se usó un índice de fusificación $m = 2.5$.

Funciones de Pertenencia A continuación se muestran las funciones de pertenencia asociadas a la proyección de cada cluster sobre cada una de las componentes de la base de regresores.

- Regla i

- Conjunto A_{i1} (regresor $P(k-1)$)

$$\mu_{i1}(x) = \frac{1}{1 + e^{-2.555465 \cdot 10^{-4} \cdot (x + 4.295659 \cdot 10^3)}} \tag{A.2.2}$$

- Conjunto A_{i2} (regresor $P(k-1)$)

$$\mu_{i2}(x) = \frac{1}{1 + e^{2.668044 \cdot 10^{-4} \cdot (x - 4.067799 \cdot 10^3)}} \quad (\text{A.2.3})$$

- Conjunto A_{i3} (regresor $v(k-1)$)

$$\mu_{i3}(x) = \frac{1}{1 + e^{1.158246 \cdot (x - 0.5727157)}} \quad (\text{A.2.4})$$

- Conjunto A_{i4} (regresor $v(k-1)$)

$$\mu_{i4}(x) = \frac{1}{1 + e^{-1.086095 \cdot (x + 0.6898401)}} \quad (\text{A.2.5})$$

- Conjunto A_{i5} (regresor $v(k-2)$)

$$\mu_{i5}(x) = \frac{1}{1 + e^{1.247471 \cdot (x - 0.5084912)}} \quad (\text{A.2.6})$$

- Conjunto A_{i6} (regresor $v(k-2)$)

$$\mu_{i6}(x) = \frac{1}{1 + e^{-1.065307 \cdot (x + 0.7023615)}} \quad (\text{A.2.7})$$

- Conjunto A_{i7} (regresor $v(k-3)$)

$$\mu_{i7}(x) = \frac{1}{1 + e^{1.072748 \cdot (x - 0.6885965)}} \quad (\text{A.2.8})$$

- Conjunto A_{i8} (regresor $v(k-3)$)

$$\mu_{i8}(x) = \frac{1}{1 + e^{-0.9791943 \cdot (x + 0.8716317)}} \quad (\text{A.2.9})$$

- Conjunto A_{i9} (regresor $\theta(k-3)$)

$$\mu_{i9}(x) = \frac{1}{1 + e^{1.441206 \cdot (x - 1.320260)}} \quad (\text{A.2.10})$$

- Conjunto A_{i10} (regresor $\theta(k - 3)$)

$$\mu_{i10}(x) = \frac{1}{1 + e^{-1.578094 \cdot (x+1.346902)}} \quad (\text{A.2.11})$$

En la Figura A.2.1 se muestran los gráficos correspondientes a las funciones de pertenencia del modelo difuso.

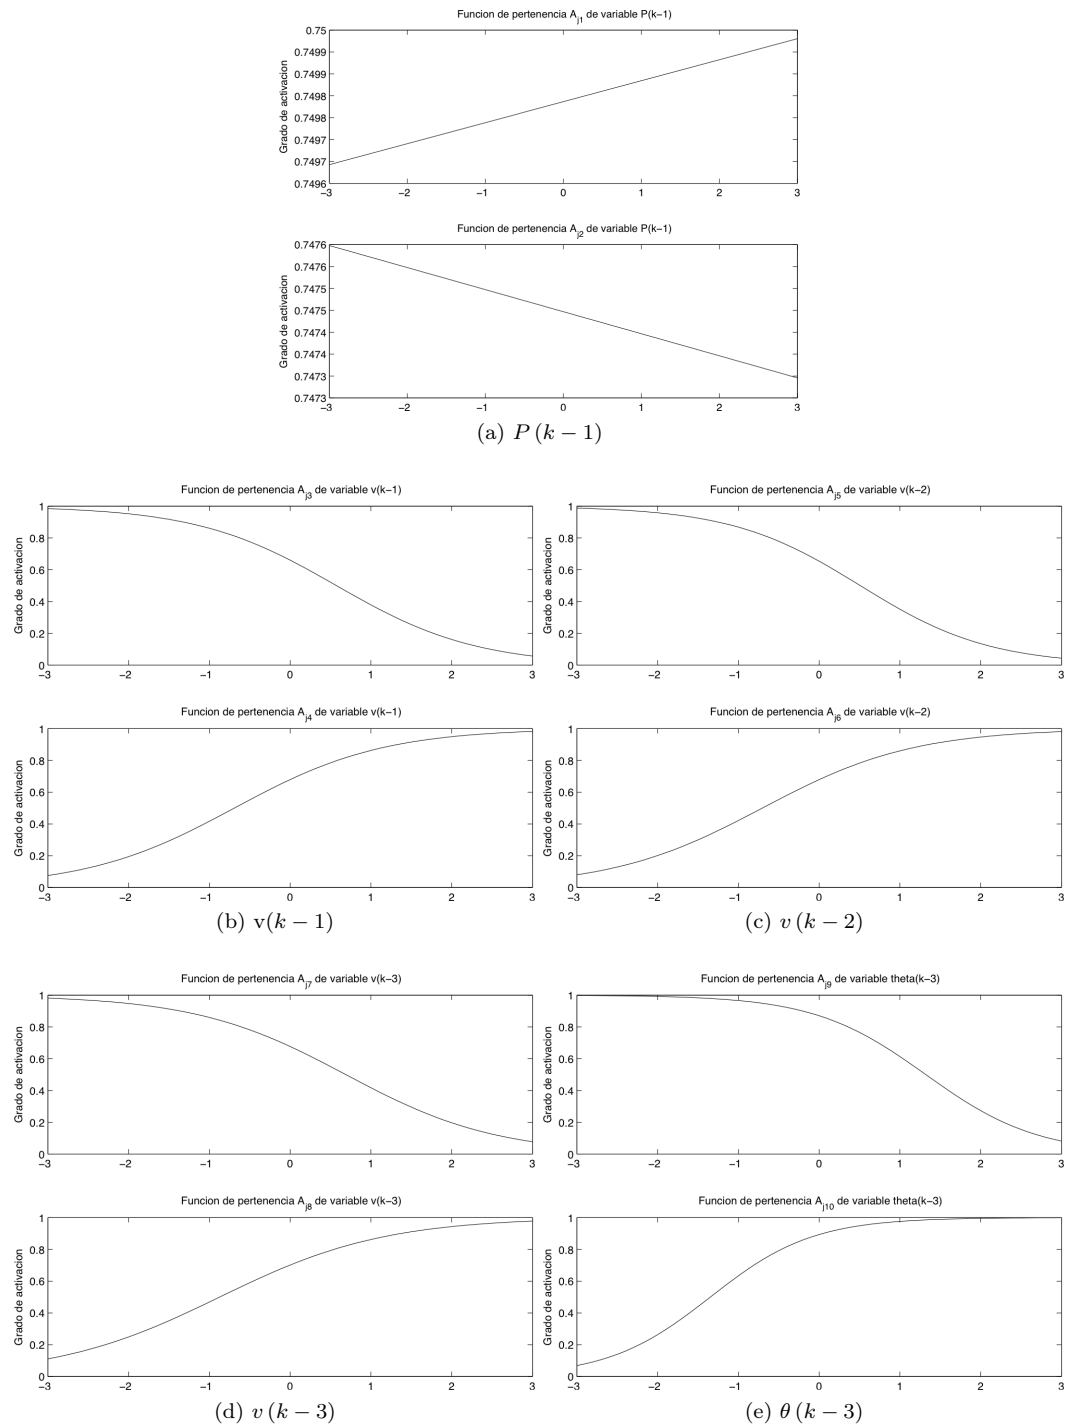


Figura A.2.1: Funciones de pertenencia.

Base de Reglas El sistema está formado por una base de tres reglas formadas por antecedentes y consecuencias. Al tratarse de un sistema difuso de Takagi - Sugeno, las consecuencias de la base de reglas están formadas por funciones lineales. A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{12} and $v(k-1)$ is A_{14} and $v(k-2)$ is A_{16} and $v(k-3)$ is A_{18} and $\theta(k-3)$ is A_{110} then $P_1(k) = 0.9521 \cdot P(k-1) - 0.5364 \cdot v(k-1) + 2.1099 \cdot v(k-2) - 1.4609 \cdot v(k-3) - 0.2743 \cdot \theta(k-3) - 1.5454$
2. If $P(k-1)$ is A_{22} and $v(k-1)$ is A_{24} and $v(k-2)$ is A_{25} and $v(k-3)$ is A_{28} and $\theta(k-3)$ is A_{210} then $P_2(k) = 1.1368 \cdot P(k-1) - 11.3823 \cdot v(k-1) - 8.3992 \cdot v(k-2) + 5.2741 \cdot v(k-3) + 2.641 \cdot \theta(k-3) - 31.0872$
3. If $P(k-1)$ is A_{31} and $v(k-1)$ is A_{33} and $v(k-2)$ is A_{35} and $v(k-3)$ is A_{38} and $\theta(k-3)$ is A_{310} then $P_3(k) = -0.1094 \cdot P(k-1) - 14.6546 \cdot v(k-1) + 8.9199 \cdot v(k-2) - 10.3252 \cdot v(k-3) - 2.4095 \cdot \theta(k-3) + 23.5873$
4. If $P(k-1)$ is A_{41} and $v(k-1)$ is A_{43} and $v(k-2)$ is A_{45} and $v(k-3)$ is A_{47} and $\theta(k-3)$ is A_{410} then $P_4(k) = 0.9345 \cdot P(k-1) - 0.453 \cdot v(k-1) - 1.9312 \cdot v(k-2) - 0.2636 \cdot v(k-3) + 0.9605 \cdot \theta(k-3) + 8.5727$
5. If $P(k-1)$ is A_{51} and $v(k-1)$ is A_{54} and $v(k-2)$ is A_{56} and $v(k-3)$ is A_{58} and $\theta(k-3)$ is A_{59} then $P_5(k) = 0.8748 \cdot P(k-1) + 0.5985 \cdot v(k-1) - 6.4358 \cdot v(k-2) + 4.9672 \cdot v(k-3) + 0.1252 \cdot \theta(k-3) + 0.2203$
6. If $P(k-1)$ is A_{61} and $v(k-1)$ is A_{63} and $v(k-2)$ is A_{66} and $v(k-3)$ is A_{68} and $\theta(k-3)$ is A_{69} then $P_6(k) = 2.7199 \cdot P(k-1) - 6.2904 \cdot v(k-1) + 27.6874 \cdot v(k-2) - 11.4202 \cdot v(k-3) + 2.1658 \cdot \theta(k-3) + 33.9696$
7. If $P(k-1)$ is A_{72} and $v(k-1)$ is A_{74} and $v(k-2)$ is A_{75} and $v(k-3)$ is A_{78} and $\theta(k-3)$ is A_{79} then $P_7(k) = -0.2279 \cdot P(k-1) + 9.916 \cdot v(k-1) - 7.632 \cdot v(k-2) + 13.6538 \cdot v(k-3) - 1.7673 \cdot \theta(k-3) + 40.0255$
8. If $P(k-1)$ is A_{82} and $v(k-1)$ is A_{83} and $v(k-2)$ is A_{85} and $v(k-3)$ is A_{88} and $\theta(k-3)$ is A_{89} then $P_8(k) = -256.1 \cdot P(k-1) - 9628 \cdot v(k-1) + 15930 \cdot v(k-2) + -1956 \cdot v(k-3) + -1305 \cdot \theta(k-3) + 27.1912$

9. If $P(k-1)$ is A_{91} and $v(k-1)$ is A_{93} and $v(k-2)$ is A_{95} and $v(k-3)$ is A_{98} and $\theta(k-3)$ is A_{99} then $P_9(k) = 258 \cdot P(k-1) + 9659 \cdot v(k-1) + -16000 \cdot v(k-2) + 1985 \cdot v(k-3) + 1310 \cdot \theta(k-3) + 0$
10. If $P(k-1)$ is A_{101} and $v(k-1)$ is A_{103} and $v(k-2)$ is A_{106} and $v(k-3)$ is A_{107} and $\theta(k-3)$ is A_{109} then $P_{10}(k) = 2.3761 \cdot P(k-1) + 20.4971 \cdot v(k-1) + -36.3171 \cdot v(k-2) + 35.3503 \cdot v(k-3) - 0.9469 \cdot \theta(k-3) - 94.9129$
11. If $P(k-1)$ is A_{112} and $v(k-1)$ is A_{113} and $v(k-2)$ is A_{115} and $v(k-3)$ is A_{117} and $\theta(k-3)$ is A_{119} then $P_{11}(k) = 0.8697 \cdot P(k-1) - 0.8626 \cdot v(k-1) + 3.1899 \cdot v(k-2) - 1.078 \cdot v(k-3) - 0.0794 \cdot \theta(k-3) - 5.1521$

Función de Salida Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función A.2.12.

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.2.12})$$

En la función A.2.12, w_r corresponde al grado de activación de la regla r . En A.2.13 se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_a+n_b}^r \quad (\text{A.2.13})$$

A.3. Modelo obtenido a partir de nuevo algoritmo (cálculo de parámetros de las consecuencias mediante PSO)

A.3.1. Modelos obtenidos por base de regresores fija

Base de regresores.

$$\begin{aligned}
 C &= 2 \\
 N_y &= 1 \\
 N_u &= \begin{bmatrix} 3 & 1 \end{bmatrix} \\
 N_d &= \begin{bmatrix} 1 & 2 \end{bmatrix}
 \end{aligned} \tag{A.3.1}$$

Clustering difuso. A continuación se muestran las funciones de pertenencia asociadas a la proyección de cada cluster sobre cada una de las componentes de la base de regresores.

■ Regla i

- Conjunto A_{i1} (regresor $P(k-1)$)

$$\mu_{i1}(x) = \frac{1}{1 + e^{-2.555465 \cdot 10^{-4} \cdot (x + 4.295659 \cdot 10^3)}} \tag{A.3.2}$$

- Conjunto A_{i2} (regresor $P(k-1)$)

$$\mu_{i2}(x) = \frac{1}{1 + e^{2.668044 \cdot 10^{-4} \cdot (x - 4.067799 \cdot 10^3)}} \tag{A.3.3}$$

- Conjunto A_{i3} (regresor $v(k-1)$)

$$\mu_{i3}(x) = \frac{1}{1 + e^{1.158246 \cdot (x - 0.5727157)}} \tag{A.3.4}$$

- Conjunto A_{i4} (regresor $v(k-1)$)

$$\mu_{i4}(x) = \frac{1}{1 + e^{-1.086095 \cdot (x + 0.6898401)}} \tag{A.3.5}$$

- Conjunto A_{i5} (regresor $v(k-2)$)

$$\mu_{i5}(x) = \frac{1}{1 + e^{1.247471 \cdot (x-0.5084912)}} \quad (\text{A.3.6})$$

- Conjunto A_{i6} (regresor $v(k-2)$)

$$\mu_{i6}(x) = \frac{1}{1 + e^{-1.065307 \cdot (x+0.7023615)}} \quad (\text{A.3.7})$$

- Conjunto A_{i7} (regresor $v(k-3)$)

$$\mu_{i7}(x) = \frac{1}{1 + e^{1.072748 \cdot (x-0.6885965)}} \quad (\text{A.3.8})$$

- Conjunto A_{i8} (regresor $v(k-3)$)

$$\mu_{i8}(x) = \frac{1}{1 + e^{-0.9791943 \cdot (x+0.8716317)}} \quad (\text{A.3.9})$$

- Conjunto A_{i9} (regresor $\theta(k-3)$)

$$\mu_{i9}(x) = \frac{1}{1 + e^{1.441206 \cdot (x-1.320260)}} \quad (\text{A.3.10})$$

- Conjunto A_{i10} (regresor $\theta(k-3)$)

$$\mu_{i10}(x) = \frac{1}{1 + e^{-1.578094 \cdot (x+1.346902)}} \quad (\text{A.3.11})$$

En la Figura A.3.1 se muestran los gráficos correspondientes a las funciones de pertenencia del modelo difuso.

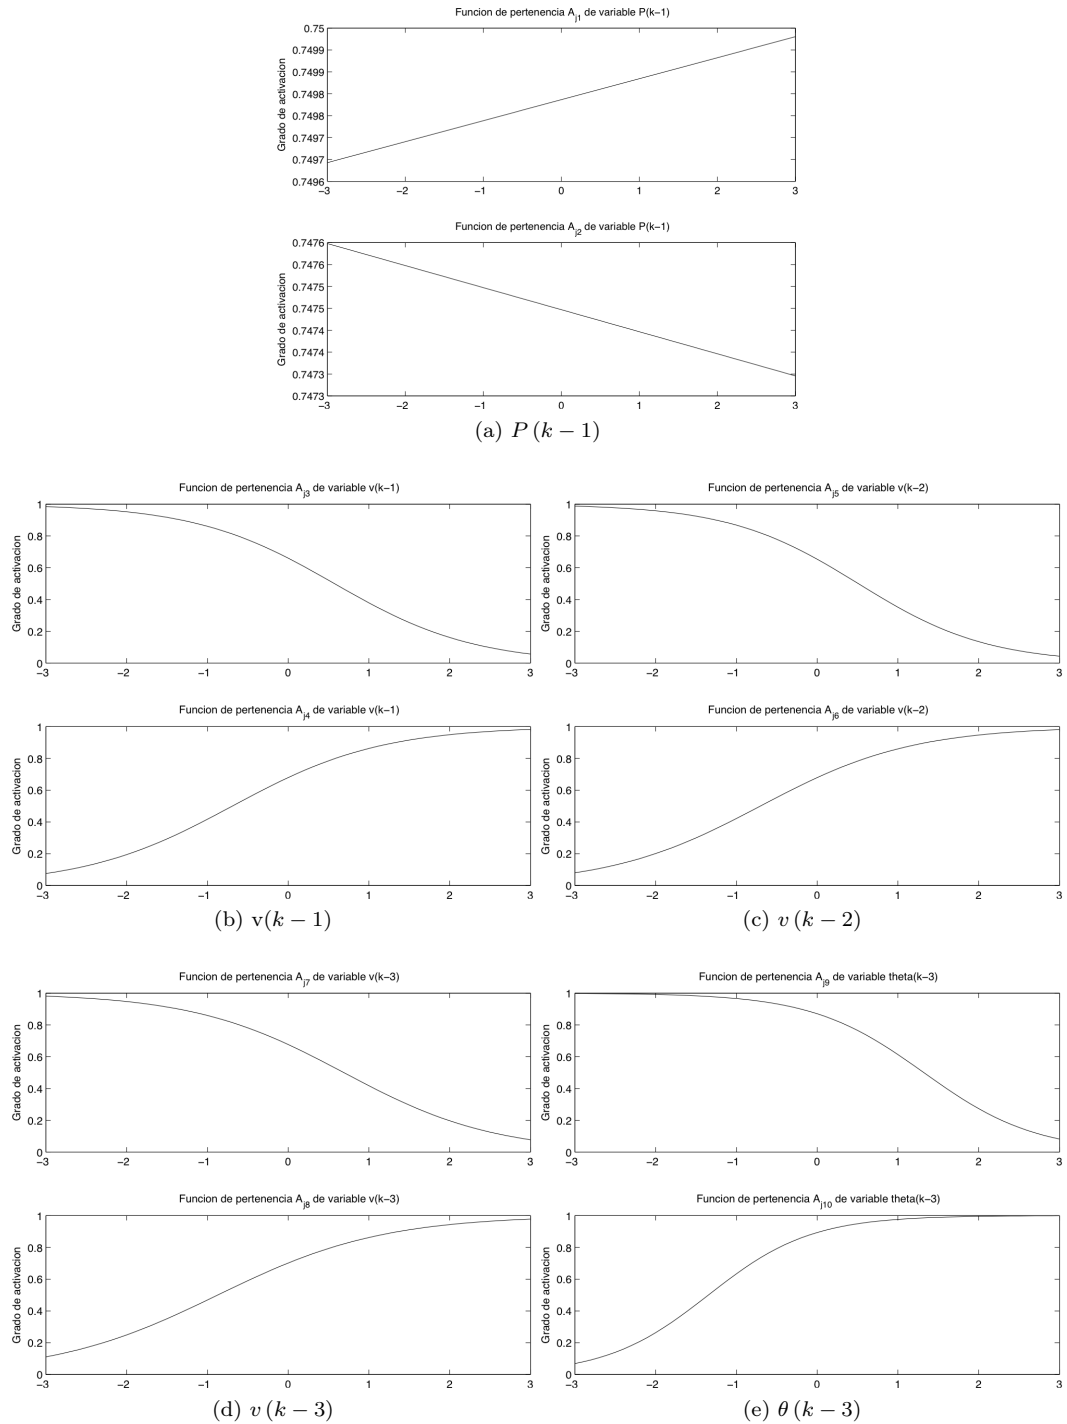


Figura A.3.1: Funciones de pertenencia.

Se realizaron 100 réplicas del método de identificación con la base de regresores y clustering indicados. El método está basado en algoritmos evolutivos cuyas condiciones iniciales son aleatorias,

por lo que en cada réplica se obtuvieron resultados diferentes.

Se seleccionaron 5 modelos. Los modelos seleccionados corresponden a los que presentaron menor *error cuadrático medio* en cada una de las pruebas realizadas.

A continuación se presentan las bases de reglas y los resultados de los modelos seleccionados en cada categoría.

A.3.1.1. Mejor modelo 1 paso

Base de Reglas El sistema está formado por una base de dos reglas formadas por antecedentes y consecuencias. Al tratarse de un sistema difuso de Takagi - Sugeno, las consecuencias de la base de reglas están formadas por funciones lineales. A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{12} and $v(k-1)$ is A_{13} and $v(k-2)$ is A_{16} and $v(k-3)$ is A_{18} and $\theta(k-3)$ is A_{110} then $P_1(k) = 0.99 \cdot P(k-1) - 0.144926 \cdot v(k-1) + 0.99 \cdot v(k-2) - 0.99 \cdot v(k-3) + 0.3308407 \cdot \theta(k-3) + 0.99$
2. If $P(k-1)$ is A_{21} and $v(k-1)$ is A_{23} and $v(k-2)$ is A_{25} and $v(k-3)$ is A_{28} and $\theta(k-3)$ is A_{210} then $P_2(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) + 0.99 \cdot v(k-2) + 0.1402561 \cdot v(k-3) - 0.1834364 \cdot \theta(k-3) - 0.99$
3. If $P(k-1)$ is A_{32} and $v(k-1)$ is A_{33} and $v(k-2)$ is A_{36} and $v(k-3)$ is A_{38} and $\theta(k-3)$ is A_{39} then $P_3(k) = 0.99 \cdot P(k-1) + 0.99 \cdot v(k-1) - 0.99 \cdot v(k-2) + 0.9136496 \cdot v(k-3) - 0.09778086 \cdot \theta(k-3) - 0.3189281$
4. If $P(k-1)$ is A_{41} and $v(k-1)$ is A_{43} and $v(k-2)$ is A_{46} and $v(k-3)$ is A_{48} and $\theta(k-3)$ is A_{49} then $P_4(k) = 0.9637986 \cdot P(k-1) - 0.1395083 \cdot v(k-1) - 0.2931169 \cdot v(k-2) - 0.1737423 \cdot v(k-3) + 0.8182983 \cdot \theta(k-3) + 0.99$
5. If $P(k-1)$ is A_{51} and $v(k-1)$ is A_{53} and $v(k-2)$ is A_{55} and $v(k-3)$ is A_{58} and $\theta(k-3)$ is A_{59} then $P_5(k) = 0.99 \cdot P(k-1) + 0.99 \cdot v(k-1) - 0.99 \cdot v(k-2) + 0.118408 \cdot v(k-3) + 0.99 \cdot \theta(k-3) - 0.99$
6. If $P(k-1)$ is A_{62} and $v(k-1)$ is A_{63} and $v(k-2)$ is A_{66} and $v(k-3)$ is A_{67} and $\theta(k-3)$ is A_{69} then $P_6(k) = 0.99 \cdot P(k-1) - 0.1253577 \cdot v(k-1) + 0.99 \cdot v(k-2) - 0.99 \cdot v(k-3) - 0.99 \cdot \theta(k-3) + -0.7292741$

7. If $P(k-1)$ is A_{71} and $v(k-1)$ is A_{73} and $v(k-2)$ is A_{75} and $v(k-3)$ is A_{77} and $\theta(k-3)$ is A_{79} then $P_7(k) = 0.99 \cdot P(k-1) - 0.1591513 \cdot v(k-1) + 0.8142855 \cdot v(k-2) - 0.9332693 \cdot v(k-3) - 0.09503132 \cdot \theta(k-3) + 0.9665745$

Función de Salida Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (A.3.12).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.3.12})$$

En la función (A.3.12), w_r corresponde al grado de activación de la regla r . En (A.3.13) se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (\text{A.3.13})$$

A.3.1.2. Mejor modelo 10 pasos

Base de Reglas A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{12} and $v(k-1)$ is A_{14} and $v(k-2)$ is A_{15} and $v(k-3)$ is A_{18} and $\theta(k-3)$ is A_{19} then $P_1(k) = 0.9492972 \cdot P(k-1) - 0.7562499 \cdot v(k-1) - 0.4776354 \cdot v(k-2) + 0.9703508 \cdot v(k-3) + 0.2534305 \cdot \theta(k-3) - 0.08613949$
2. If $P(k-1)$ is A_{21} and $v(k-1)$ is A_{23} and $v(k-2)$ is A_{26} and $v(k-3)$ is A_{27} and $\theta(k-3)$ is A_{29} then $P_2(k) = 0.99 \cdot P(k-1) - 0.3380257 \cdot v(k-1) + 0.3156378 \cdot v(k-2) - 0.02367881 \cdot v(k-3) + 0.1033942 \cdot \theta(k-3) + 0.06499108$

Función de Salida Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (A.3.14).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.3.14})$$

En la función (A.3.14), w_r corresponde al grado de activación de la regla r . En (A.3.15) se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_a+n_b}^r \quad (\text{A.3.15})$$

A.3.1.3. Mejor modelo 10 pasos (viento promedio)

A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{12} and $v(k-1)$ is A_{13} and $v(k-2)$ is A_{16} and $v(k-3)$ is A_{18} and $\theta(k-3)$ is A_{110} then $P_1(k) = 0.99 \cdot P(k-1) - 0.144926 \cdot v(k-1) + 0.99 \cdot v(k-2) - 0.99 \cdot v(k-3) + 0.3308407 \cdot \theta(k-3) + 0.99$
2. If $P(k-1)$ is A_{21} and $v(k-1)$ is A_{23} and $v(k-2)$ is A_{25} and $v(k-3)$ is A_{28} and $\theta(k-3)$ is A_{210} then $P_2(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) + 0.99 \cdot v(k-2) + 0.1402561 \cdot v(k-3) - 0.1834364 \cdot \theta(k-3) - 0.99$
3. If $P(k-1)$ is A_{32} and $v(k-1)$ is A_{33} and $v(k-2)$ is A_{36} and $v(k-3)$ is A_{38} and $\theta(k-3)$ is A_{39} then $P_3(k) = 0.99 \cdot P(k-1) + 0.99 \cdot v(k-1) - 0.99 \cdot v(k-2) + 0.9136496 \cdot v(k-3) - 0.09778086 \cdot \theta(k-3) - 0.3189281$
4. If $P(k-1)$ is A_{41} and $v(k-1)$ is A_{43} and $v(k-2)$ is A_{46} and $v(k-3)$ is A_{48} and $\theta(k-3)$ is A_{49} then $P_4(k) = 0.9637986 \cdot P(k-1) - 0.1395083 \cdot v(k-1) - 0.2931169 \cdot v(k-2) - 0.1737423 \cdot v(k-3) + 0.8182983 \cdot \theta(k-3) + 0.99$
5. If $P(k-1)$ is A_{51} and $v(k-1)$ is A_{53} and $v(k-2)$ is A_{55} and $v(k-3)$ is A_{58} and $\theta(k-3)$ is A_{59} then $P_5(k) = 0.99 \cdot P(k-1) + 0.99 \cdot v(k-1) - 0.99 \cdot v(k-2) + 0.118408 \cdot v(k-3) + 0.99 \cdot \theta(k-3) - 0.99$
6. If $P(k-1)$ is A_{62} and $v(k-1)$ is A_{63} and $v(k-2)$ is A_{66} and $v(k-3)$ is A_{67} and $\theta(k-3)$ is A_{69} then $P_6(k) = 0.99 \cdot P(k-1) - 0.1253577 \cdot v(k-1) + 0.99 \cdot v(k-2) - 0.99 \cdot v(k-3) - 0.99 \cdot \theta(k-3) + -0.7292741$
7. If $P(k-1)$ is A_{71} and $v(k-1)$ is A_{73} and $v(k-2)$ is A_{75} and $v(k-3)$ is A_{77} and $\theta(k-3)$ is A_{79} then $P_7(k) = 0.99 \cdot P(k-1) - 0.1591513 \cdot v(k-1) + 0.8142855 \cdot v(k-2) - 0.9332693 \cdot v(k-3) - 0.09503132 \cdot \theta(k-3) + 0.9665745$

Función de Salida Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (A.3.16).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.3.16})$$

En la función (A.3.16), w_r corresponde al grado de activación de la regla r . En (A.3.17) se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (\text{A.3.17})$$

A.3.1.4. Mejor modelo N pasos

A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{12} and $v(k-1)$ is A_{13} and $v(k-2)$ is A_{16} and $v(k-3)$ is A_{18} and $\theta(k-3)$ is A_{110} then $P_1(k) = 0.99 \cdot P(k-1) - 0.5788827 \cdot v(k-1) - 0.99 \cdot v(k-2) + 0.99 \cdot v(k-3) - 0.7880333 \cdot \theta(k-3) - 0.99$
2. If $P(k-1)$ is A_{22} and $v(k-1)$ is A_{24} and $v(k-2)$ is A_{25} and $v(k-3)$ is A_{28} and $\theta(k-3)$ is A_{210} then $P_2(k) = 0.99 \cdot P(k-1) + 0.99 \cdot v(k-1) + 0.99 \cdot v(k-2) + 0.09798912 \cdot v(k-3) - 0.99 \cdot \theta(k-3) + 0.4925102$
3. If $P(k-1)$ is A_{32} and $v(k-1)$ is A_{33} and $v(k-2)$ is A_{36} and $v(k-3)$ is A_{37} and $\theta(k-3)$ is A_{310} then $P_3(k) = 0.99 \cdot P(k-1) + 0.1548762 \cdot v(k-1) + 0.99 \cdot v(k-2) - 0.99 \cdot v(k-3) + 0.99 \cdot \theta(k-3) - 0.99$
4. If $P(k-1)$ is A_{41} and $v(k-1)$ is A_{43} and $v(k-2)$ is A_{46} and $v(k-3)$ is A_{47} and $\theta(k-3)$ is A_{410} then $P_4(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) - 0.99 \cdot v(k-2) - 0.99 \cdot v(k-3) - 0.01774583 \cdot \theta(k-3) - 0.99$
5. If $P(k-1)$ is A_{52} and $v(k-1)$ is A_{54} and $v(k-2)$ is A_{55} and $v(k-3)$ is A_{57} and $\theta(k-3)$ is A_{510} then $P_5(k) = 0.99 \cdot P(k-1) + 0.99 \cdot v(k-1) + 0.99 \cdot v(k-2) + 0.99 \cdot v(k-3) - 0.4420350 \cdot \theta(k-3) + 0.1711968$
6. If $P(k-1)$ is A_{61} and $v(k-1)$ is A_{64} and $v(k-2)$ is A_{65} and $v(k-3)$ is A_{67} and $\theta(k-3)$ is A_{610} then $P_6(k) = 0.99 \cdot P(k-1) + 0.7633051 \cdot v(k-1) - 0.9410242 \cdot v(k-2) - 0.6028554 \cdot$

$$v(k-3) + 0.99 \cdot \theta(k-3) + 0.99$$

7. If $P(k-1)$ is A_{72} and $v(k-1)$ is A_{74} and $v(k-2)$ is A_{76} and $v(k-3)$ is A_{78} and $\theta(k-3)$ is A_{79} then $P_7(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) + 0.99 \cdot v(k-2) - 0.99 \cdot v(k-3) + 0.99 \cdot \theta(k-3) - 0.99$
8. If $P(k-1)$ is A_{81} and $v(k-1)$ is A_{84} and $v(k-2)$ is A_{85} and $v(k-3)$ is A_{88} and $\theta(k-3)$ is A_{89} then $P_8(k) = 0.6561336 \cdot P(k-1) - 0.99 \cdot v(k-1) - 0.99 \cdot v(k-2) - 0.99 \cdot v(k-3) + 0.99 \cdot \theta(k-3) + 0.99$
9. If $P(k-1)$ is A_{92} and $v(k-1)$ is A_{93} and $v(k-2)$ is A_{95} and $v(k-3)$ is A_{98} and $\theta(k-3)$ is A_{99} then $P_9(k) = 0.99 \cdot P(k-1) - 0.1094269 \cdot v(k-1) + 0.4328767 \cdot v(k-2) - 0.99 \cdot v(k-3) + 0.99 \cdot \theta(k-3) + 0.99$
10. If $P(k-1)$ is A_{101} and $v(k-1)$ is A_{103} and $v(k-2)$ is A_{105} and $v(k-3)$ is A_{108} and $\theta(k-3)$ is A_{109} then $P_{10}(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) + 0.99 \cdot v(k-2) + 0.99 \cdot v(k-3) - 0.99 \cdot \theta(k-3) - 0.99$
11. If $P(k-1)$ is A_{112} and $v(k-1)$ is A_{114} and $v(k-2)$ is A_{116} and $v(k-3)$ is A_{117} and $\theta(k-3)$ is A_{119} then $P_{11}(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) + 0.99 \cdot v(k-2) + 0.99 \cdot v(k-3) - 0.99 \cdot \theta(k-3) - 0.99$
12. If $P(k-1)$ is A_{122} and $v(k-1)$ is A_{123} and $v(k-2)$ is A_{126} and $v(k-3)$ is A_{127} and $\theta(k-3)$ is A_{129} then $P_{12}(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) - 0.1841159 \cdot v(k-2) + 0.99 \cdot v(k-3) + 0.99 \cdot \theta(k-3) + 0.99$
13. If $P(k-1)$ is A_{131} and $v(k-1)$ is A_{133} and $v(k-2)$ is A_{136} and $v(k-3)$ is A_{137} and $\theta(k-3)$ is A_{139} then $P_{13}(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) + 0.6938976 \cdot v(k-2) - 0.99 \cdot v(k-3) - 0.4380987 \cdot \theta(k-3) + 0.99$

Función de Salida Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (A.3.18).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.3.18})$$

En la función (A.3.18), w_r corresponde al grado de activación de la regla r . En (A.3.19) se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (\text{A.3.19})$$

A.3.1.5. Mejor modelo N pasos (viento promedio)

A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{12} and $v(k-1)$ is A_{14} and $v(k-2)$ is A_{16} and $v(k-3)$ is A_{18} and $\theta(k-3)$ is A_{110} then $P_1(k) = 0.99 \cdot P(k-1) + 0.31 \cdot v(k-1) + 0.6850616 \cdot v(k-2) - 0.09541743 \cdot v(k-3) - 0.5293904 \cdot \theta(k-3) + 0.99$
2. If $P(k-1)$ is A_{22} and $v(k-1)$ is A_{24} and $v(k-2)$ is A_{25} and $v(k-3)$ is A_{28} and $\theta(k-3)$ is A_{210} then $P_2(k) = 0.99 \cdot P(k-1) + 0.99 \cdot v(k-1) - 0.3258947 \cdot v(k-2) - 0.008202238 \cdot v(k-3) + 0.02816628 \cdot \theta(k-3) + 0.09040111$
3. If $P(k-1)$ is A_{31} and $v(k-1)$ is A_{33} and $v(k-2)$ is A_{35} and $v(k-3)$ is A_{38} and $\theta(k-3)$ is A_{310} then $P_3(k) = 0.99 \cdot P(k-1) + 0.02858108 \cdot v(k-1) + 0.5445651 \cdot v(k-2) + 0.99 \cdot v(k-3) + 0.99 \cdot \theta(k-3) - 0.99$
4. If $P(k-1)$ is A_{41} and $v(k-1)$ is A_{43} and $v(k-2)$ is A_{45} and $v(k-3)$ is A_{47} and $\theta(k-3)$ is A_{410} then $P_4(k) = 0.99 \cdot P(k-1) + 0.99 \cdot v(k-1) - 0.5607764 \cdot v(k-2) - 0.99 \cdot v(k-3) + 0.06.567468 \cdot \theta(k-3) + 0.8148964$
5. If $P(k-1)$ is A_{51} and $v(k-1)$ is A_{54} and $v(k-2)$ is A_{56} and $v(k-3)$ is A_{58} and $\theta(k-3)$ is A_{59} then $P_5(k) = 0.99 \cdot P(k-1) + 0.4523932 \cdot v(k-1) - 0.99 \cdot v(k-2) - 0.3654610 \cdot v(k-3) + 0.9124413 \cdot \theta(k-3) - 0.2357836$
6. If $P(k-1)$ is A_{61} and $v(k-1)$ is A_{63} and $v(k-2)$ is A_{66} and $v(k-3)$ is A_{68} and $\theta(k-3)$ is A_{69} then $P_6(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) + 0.1462631 \cdot v(k-2) - 0.08187001 \cdot v(k-3) - 0.04051595 \cdot \theta(k-3) + 0.1328418$
7. If $P(k-1)$ is A_{72} and $v(k-1)$ is A_{74} and $v(k-2)$ is A_{75} and $v(k-3)$ is A_{78} and $\theta(k-3)$ is A_{79} then $P_7(k) = 0.99 \cdot P(k-1) + 0.7002182 \cdot v(k-1) - 0.99 \cdot v(k-2) + 0.99 \cdot v(k-3) - 0.99 \cdot \theta(k-3) + 0.3794952$

8. If $P(k-1)$ is A_{82} and $v(k-1)$ is A_{83} and $v(k-2)$ is A_{85} and $v(k-3)$ is A_{88} and $\theta(k-3)$ is A_{89} then $P_8(k) = 0.99 \cdot P(k-1) - 0.9259028 \cdot v(k-1) - 0.4146331 \cdot v(k-2) - 0.99 \cdot v(k-3) + 0.5477697 \cdot \theta(k-3) - 0.99$
9. If $P(k-1)$ is A_{91} and $v(k-1)$ is A_{93} and $v(k-2)$ is A_{95} and $v(k-3)$ is A_{98} and $\theta(k-3)$ is A_{99} then $P_9(k) = 0.7589536 \cdot P(k-1) + 0.5180589 \cdot v(k-1) + 0.99 \cdot v(k-2) + 0.2420615 \cdot v(k-3) + 0.99 \cdot \theta(k-3) - 0.99$
10. If $P(k-1)$ is A_{101} and $v(k-1)$ is A_{103} and $v(k-2)$ is A_{106} and $v(k-3)$ is A_{107} and $\theta(k-3)$ is A_{109} then $P_{10}(k) = 0.99 \cdot P(k-1) - 0.99 \cdot v(k-1) + 0.7787150 \cdot v(k-2) - 0.5438522 \cdot v(k-3) - 0.05558236 \cdot \theta(k-3) + 0.6989046$
11. If $P(k-1)$ is A_{112} and $v(k-1)$ is A_{113} and $v(k-2)$ is A_{115} and $v(k-3)$ is A_{117} and $\theta(k-3)$ is A_{119} then $P_{11}(k) = 0.99 \cdot P(k-1) - 0.2608025 \cdot v(k-1) + 0.6971225 \cdot v(k-2) - 0.3636548 \cdot v(k-3) + 0.01114484 \cdot \theta(k-3) + 0.01985363$

Función de Salida Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (A.3.20).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.3.20})$$

En la función (A.3.20), w_r corresponde al grado de activación de la regla r . En (A.3.21) se muestra la definición de w_r .


$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (\text{A.3.21})$$

Resultados En la Tabla A.3.1 se muestran los índices que muestran la calidad de las diferentes predicciones realizadas con el modelo.


Cuadro A.3.1: Resultados modelo difuso obtenido por nuevo método (mejor modelo predicción a N pasos, viento promedio).

Prueba	ECM	VAF
Predicción 1 Paso	0,1317	98,2669 %
Predicción 10 Pasos (Viento Conocido)	0,3546	87,4843 %
Predicción 10 Pasos (Viento Promedio)	0,6417	59,7951 %
Predicción N Pasos (Viento Conocido)	0,6476	60,0552 %
Predicción N Pasos (Viento Promedio)	0,8331	40,5174 %


A modo de ilustración acerca del desempeño del sistema frente de las distintas predicciones propuestas, en la Figura A.3.2 se muestran gráficos de una parte de las predicciones realizadas con el conjunto de datos de validación.



(a) 1 Paso



(b) 10 Pasos



(c) N Pasos

Figura A.3.2: Predicciones modelo difuso obtenido por nuevo método (mejor modelo predicción a N pasos, viento promedio).

A.3.2. Modelos obtenidos por análisis de sensibilidad

Base de Regresores

$$\begin{aligned}
 C &= 2 \\
 N_y &= 2 \\
 N_u &= \begin{bmatrix} 1 & 1 \end{bmatrix} \\
 N_d &= \begin{bmatrix} 2 & 2 \end{bmatrix}
 \end{aligned} \tag{A.3.22}$$

Clustering difuso. Los clusters obtenidos se aproximaron por funciones sigmoideas. A continuación se muestran las funciones de pertenencia asociadas a la proyección de cada cluster sobre cada una de las componentes de la base de regresores.

■ Regla i

- Conjunto A_{i1} (regresor $P(k-1)$)

$$\mu_{i1}(x) = \frac{1}{1 + e^{-2.555465 \cdot 10^4 \cdot (x + 4.295659 \cdot 10^3)}} \tag{A.3.23}$$

- Conjunto A_{i2} (regresor $P(k-1)$)

$$\mu_{i2}(x) = \frac{1}{1 + e^{2.668044 \cdot 10^4 \cdot (x - 4.067799 \cdot 10^3)}} \tag{A.3.24}$$

- Conjunto A_{i3} (regresor $P(k-2)$)

$$\mu_{i3}(x) = \frac{1}{1 + e^{-2.555465 \cdot 10^4 \cdot (x + 4.295659 \cdot 10^3)}} \tag{A.3.25}$$

- Conjunto A_{i4} (regresor $P(k-2)$)

$$\mu_{i4}(x) = \frac{1}{1 + e^{-2.668044 \cdot 10^4 \cdot (x - 4.067799 \cdot 10^3)}} \tag{A.3.26}$$

- Conjunto A_{i5} (regresor $v(k-3)$)

$$\mu_{i5}(x) = \frac{1}{1 + e^{-1.072748 \cdot (x-0.6885965)}} \quad (\text{A.3.27})$$

- Conjunto A_{i6} (regresor $v(k-3)$)

$$\mu_{i6}(x) = \frac{1}{1 + e^{-0.9791943 \cdot (x+0.8716317)}} \quad (\text{A.3.28})$$

- Conjunto A_{i7} (regresor $\theta(k-3)$)

$$\mu_{i7}(x) = \frac{1}{1 + e^{1.441206 \cdot (x-1.32026)}} \quad (\text{A.3.29})$$

- Conjunto A_{i8} (regresor $\theta(k-3)$)

$$\mu_{i8}(x) = \frac{1}{1 + e^{-1.578094 \cdot (x+1.346902)}} \quad (\text{A.3.30})$$

En la Figura A.3.3 se muestran los gráficos correspondientes a las funciones de pertenencia del modelo difuso.

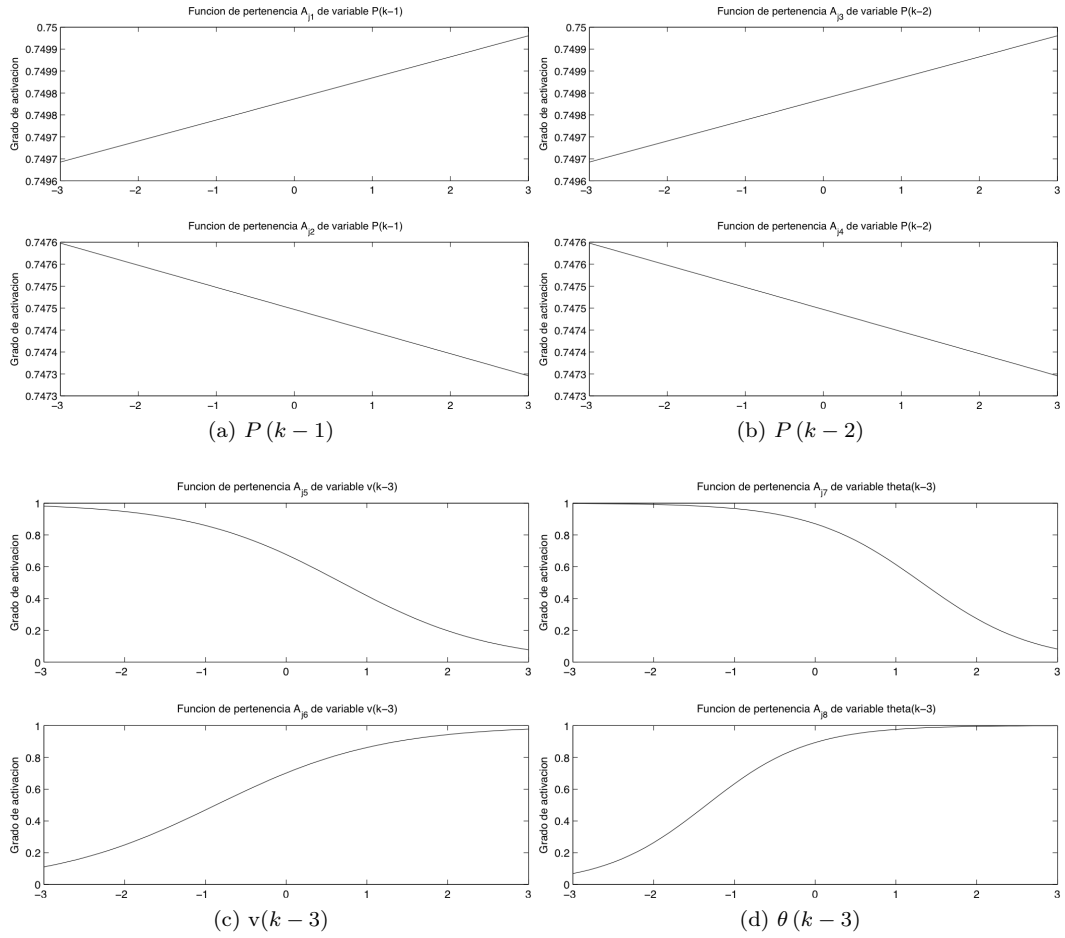


Figura A.3.3: Funciones de pertenencia.

Base de Reglas El sistema está formado por una base de tres reglas formadas por antecedentes y consecuencias. Al tratarse de un sistema difuso de Takagi - Sugeno, las consecuencias de la base de reglas están formadas por funciones lineales. A continuación se muestra la base de reglas correspondiente al sistema.

1. If $P(k-1)$ is A_{12} and $P(k-2)$ is A_{14} and $v(k-3)$ is A_{15} and $\theta(k-3)$ is A_{18} then $P_1(k) = 0.9488901 \cdot P(k-1) + 0.99 \cdot P(k-2) - 0.3665309 \cdot v(k-3) - 0.99 \cdot \theta(k-3) - 0.252208$
2. If $P(k-1)$ is A_{22} and $P(k-2)$ is A_{23} and $v(k-3)$ is A_{25} and $\theta(k-3)$ is A_{28} then $P_2(k) = 0.99 \cdot P(k-1) + 0.01457491 \cdot P(k-2) - 0.4784831 \cdot v(k-3) + 0.99 \cdot \theta(k-3) + 0.99$
3. If $P(k-1)$ is A_{31} and $P(k-2)$ is A_{33} and $v(k-3)$ is A_{35} and $\theta(k-3)$ is A_{38} then $P_3(k) =$

$$0.99 \cdot P(k-1) - 0.99 \cdot P(k-2) + 0.6990721 \cdot v(k-3) + 0.2506914 \cdot \theta(k-3) - 0.7367304$$

Función de Salida Dado que el modelo identificado es de Takagi – Sugeno, la salida del sistema está dada por la función (A.3.31).

$$y(k) = \frac{\sum_{r=1}^{N_r} w_r y_r(k)}{\sum_{r=1}^{N_r} w_r} \quad (\text{A.3.31})$$

En la función (A.3.31), w_r corresponde al grado de activación de la regla r . En (A.3.32) se muestra la definición de w_r .

$$w_r = \mu_1^r \cdots \mu_i^r \cdots \mu_{n_y+n_u}^r \quad (\text{A.3.32})$$