



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FISICAS Y MATEMATICAS
DEPARTAMENTO DE INGENIERIA ELECTRICA

**“DISEÑO E IMPLEMENTACIÓN DE ESTRATEGIAS DE CONTROL PREDICTIVO
SUPERVISOR APLICADAS A LA CALDERA DE UNA CENTRAL
TERMOELÉCTRICA DE CICLO COMBINADO”**

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

JUAN ALBERTO SOLÍS CASTRO

**PROFESOR GUÍA:
DORIS SÁEZ HUEICHAPÁN**

**MIEMBROS DE LA COMISION:
PABLO ESTEVEZ VALENCIA
GONZALO ACUÑA LEIVA**

**SANTIAGO DE CHILE
JUNIO 2010**

RESUMEN DE LA TESIS PARA OPTAR AL
GRADO DE MAGISTER EN CIENCIAS DE LA
INGENIERÍA MENCIÓN ELÉCTRICA
POR: JUAN ALBERTO SOLÍS CASTRO
FECHA: 14/06/2010
PROFESOR GUÍA: SRA. DORIS SÁEZ H.

“Diseño e Implementación de Estrategias de Control Predictivo Supervisor aplicadas a la Caldera de una Central Termoeléctrica de Ciclo Combinado”

En esta tesis se aplican los algoritmos de computación evolutiva como una eficiente herramienta de resolución del problema de control predictivo difuso basado en modelos de Takagi – Sugeno (T&S). Se plantea la metodología de formulación general en tiempo discreto del problema predictivo difuso basado en los siguientes algoritmos evolutivos: algoritmo genético simple (SGA), *Deterministic Crowding* (DC) y *Particle Swarm Optimization*(PSO).

Estas formulaciones basadas en algoritmos evolutivos se implementan en MATLAB SIMULINK y son aplicadas a una serie de problemas *benchmark* que muestran las ventajas y desventajas de cada uno de los mencionados algoritmos. Se realiza una sensibilización de los parámetros relevantes de cada uno de los algoritmos y se selecciona la mejor estrategia según sus parámetros.

El desafío principal de la tesis es la implementación de la mejor solución basada en algoritmos de computación evolutiva en la Caldera o Generadora de Vapor por Recuperación de Calor de una Planta Termoeléctrica de Ciclo Combinado. Este tipo de plantas termoeléctricas mejoran la eficiencia energética de un combustible fósil por medio de la recuperación del calor de la fuente fría de una turbina a gas y su utilización para generar vapor para el funcionamiento de una turbina a vapor. Este problema es de alta complejidad y no linealidad. La implementación de la solución basada en algoritmos evolutivos es comparada con las tradicionales para evaluar su funcionamiento.

Por último, se destaca que el aporte de esta tesis radica en el análisis de los algoritmos de computación evolutiva (GAs y PSO) aplicado a un problema altamente no lineal dado por la optimización de plantas termoeléctricas, que debe ser resuelto en tiempo real.

Agradecimientos

Primero que nada a mi Dios, Jehová, que fue mi gran apoyo en cada instante en que necesite ayuda, que no fueron pocos, y va para él toda la gloria de este logro.

Agradecido de mi profesora, Doris Sáez, quién me enseñó a trabajar con excelencia y no conformarme con resultados mediocres sino siempre luchar por lo óptimo, y no dejar las cosas sin terminar, ¡muchas gracias!. Además, de mi profesor, Pablo Estévez, quién me ayudó a ver las cosas de una óptica diferente y que errar es humano y se pueden enmendar los errores con esfuerzo y perseverancia. Al profesor Gonzalo Acuña, que me entregó una visión optimista de esta tesis y alimentó el deseo de perseverar en esta línea de investigación. A todos mis profesores, ¡Muchas gracias!

Quiero agradecer también a mis compañeros que ayudaran de diferentes formas al buen término de esta tesis, principalmente los de Control Avanzado 2, Fredy, Alfredo, Pablo, Roberto, Pato, y los nuevos integrantes que saben quienes son.

En mi trabajo, también agradecer a mis jefes, que me dieron las facilidades para terminar este logro tan importante en mi vida universitaria. Muchas gracias, Don Mario, Reynaldo, Don Luis, Paulina, Edison. A mis compañeros de trabajo que ayudaron con su experiencia en turbinas, tesis y otros menesteres.

Y, principalmente, a aquellos que acompañaron, acompañan y acompañarán mi vida, y que con su ayuda emocional, económica en muchos casos, espiritual, pedagógica y de muchas otras maneras, sustentaron mis estudios de Magíster. Mis Padres, Rosa y Juan, mis hermanas, Miriam y Rosita, a mi cuñado, Iván. Mis abuelitas, Nieve y Panchita. Y a la compañera de mi vida, Marisol.

Índice

1.	Introducción.....	3
1.1.	Motivación de la Tesis.....	3
1.2.	Estructura de la Tesis.....	6
2.	Control Predictivo Basado en Modelos No lineales (NMPC).....	7
2.1.	Introducción.....	7
2.2.	Aplicaciones Industriales MPC.....	11
2.3.	Modelación Difusa en NMPC.....	15
2.3.1.	Modelos Difusos Relacionales.....	16
2.3.2.	Modelos Difusos Takagi & Sugeno.....	17
2.4.	Estrategias de Control Avanzado aplicado a Plantas Termoeléctricas.....	20
3.	Control Predictivo Difuso T&S basado en Algoritmos de Computación Evolutiva.....	25
3.1.	Introducción.....	25
3.2.	Planteamiento del Problema.....	25
3.2.1.	Predictor Difuso T&S.....	26
3.2.2.	FPC- Problema de Optimización.....	27
3.3.	Solución a FPC: Algoritmos de Optimización.....	29
3.3.1.	Algoritmos de Optimización Convencional.....	29
3.3.2.	Algoritmos de Optimización Propuestos.....	32
3.4.	Discusión.....	49
4.	FPC basado en Algoritmos Evolutivos Aplicados a Series benchmark.....	50
4.1.	Introducción.....	50
4.1.1.	Serie 1.....	51
4.1.2.	Serie 2.....	56
4.1.3.	Serie 3.....	60
4.2.	Discusión.....	63
5.	Aplicación al Control de una Caldera Recuperadora de Calor de una Central Termoeléctrica de Ciclo Combinado.....	65
5.1.	Introducción.....	65
5.2.	Planteamiento del Problema de Control Supervisor.....	66
5.2.1.	Función Objetivo.....	66
5.2.2.	Restricciones.....	68
5.2.3.	Parámetros.....	69
5.3.	Control Supervisor basado en Modelos Difusos de la Caldera.....	70
5.3.1.	Modelo del Controlador PI.....	76
5.3.2.	Resultados de Control.....	78
6.	Conclusiones.....	86
7.	Referencias.....	90
8.	Anexos.....	98
I.	Identificación de Series.....	99
I.1.	Introducción.....	99
II.	Centrales Termoeléctricas de Ciclo Combinado.....	107
II.1.	Introducción.....	107
II.2.	Análisis Termodinámico.....	108
II.3.	Características de Centrales Termoeléctricas de Ciclo Combinado.....	110
II.3.1.	Principales Componentes de Centrales Termoeléctricas de Ciclo Combinado.....	112
II.3.2.	Principales Características de los Modelos Utilizados.....	126

1. Introducción

1.1. Motivación de la Tesis

Los sistemas de control aplicados a plantas industriales han cumplido históricamente con tratar de satisfacer de manera óptima los objetivos operacionales y mediante esto apoyar el cumplimiento de los objetivos económicos de las empresas.

Los tres objetivos operacionales generalmente son de nivel regulatorio y se enfocan en aspectos como la reducción de la influencia de perturbaciones externas, estabilización, optimización del desempeño del proceso y otros aspectos planteados a nivel técnico. Sin embargo, la realidad de las empresas es que el cumplimiento óptimo de los objetivos técnicos es sólo el punto de partida. A éstos se les deben añadir objetivos adicionales relacionados con la maximización del beneficio económico de las empresas. Esto se puede satisfacer por medio de maximizar los ingresos derivados de cada proceso controlado o de minimizar sus costos operacionales. Otros objetivos que se deben satisfacer de manera óptima están relacionados con aspectos ambientales, de seguridad entre otros.

Tradicionalmente la disciplina de la instrumentación y control se ha fijado principalmente en el cumplimiento satisfactorio de los objetivos de nivel regulatorio con controladores del tipo PID y de control avanzado que no incorporan los objetivos económicos. Además, estos sistemas de control tradicionales en su mayoría permiten un trabajo aceptable con sistemas industriales de tipo lineal pero no pueden manejar de manera óptima sistemas no lineales.

Esta situación hoy día se ha vuelto más crítica porque las empresas se enfrentan a un mercado cada vez más competitivo. Una solución que se ha propuesto e implementado exitosamente para manejar ambos objetivos son las estrategias de control predictivo a nivel supervisor no lineal (Sáez *et al.*, 2002). Éstas permiten incorporar tanto los objetivos operacionales como los criterios económicos y ambientales, y con esto cumplir con todos los exigentes requerimientos de diseño actuales.

La mayoría de las estrategias de control a nivel supervisor se resuelven con métodos de Control Predictivo Basado en Modelos (MPC, Model Predictive Control) (Richalet *et al.*, 1976). Estas estrategias se han utilizado como una herramienta eficiente para manejar este tipo de problemas.

En la industria, por lo general, se presentan comportamientos no lineales, donde los modelos lineales no han sido eficientes para representar sus comportamientos. Por esto, se hace cada vez más frecuente el uso de modelos no lineales.

En la presente tesis aplicaremos, como primer aspecto, una estrategia de control predictivo supervisor no lineal a una planta termoeléctrica de ciclo combinado, específicamente en la Caldera del tipo Recuperadora de Calor y Generadora de Vapor (HRSG, Heat Recovery Steam Generator) de este tipo de planta.

Como segundo aspecto a aplicar en el presente trabajo nos centraremos en el tipo de algoritmo de solución del problema de control predictivo. El problema planteado en las estrategias MPC no lineal (NMPC) es cuadrático, no lineal y con restricciones no lineales por lo que los algoritmos de solución se encuentran con un problema altamente complejo y que necesita ser resuelto en un tiempo determinado que puede o no ser satisfecho por el tiempo de resolución del problema cuadrático no lineal. La no linealidad de las restricciones de la estrategia NMPC está asociada al modelo que se utiliza para representar la planta. Nos centraremos en los modelos del tipo difuso.

Los algoritmos de solución convencionales basados en gradiente han tenido dificultades para manejar los problemas de optimización complejos y altamente no lineales debido a que no entregan una solución razonable en un tiempo aceptable, pueden caer en mínimos locales, y ocupan un elevado espacio de memoria computacional.

Para resolver este problema, en los últimos años ha habido un gran desarrollo la aplicación de los algoritmos de optimización no lineal basados en computación evolutiva que realizan una búsqueda estocástica en el espacio de soluciones factibles. Esto les permite manejar de una manera más eficiente el problema de los mínimos locales y en algunos casos permite mejorar el tiempo computacional.

En esta tesis se utilizan los siguientes algoritmos de computación evolutiva: Algoritmos Genéticos (GA), Algoritmos Genéticos basados en Nichos (NGA), y Particle Swarm Optimization (PSO) para resolver el problema de optimización de la estrategia de control predictivo difuso (FPC, Fuzzy Predictive Control) basado en modelos del tipo Takagi y Sugeno (T&S) aplicada al control por simulación de una caldera de una planta termoeléctrica de ciclo combinado.

1.2. Estructura de la Tesis

En esta tesis, se presenta una metodología de diseño de estrategias de FPC basadas en algoritmos evolutivos que consideran las ventajas y desventajas de su aplicación a problemas de control no lineales. Finalmente, se aplicará esta estrategia de control a una caldera de una planta termoeléctrica de ciclo combinado.

En el capítulo 2 se analiza la teoría del control predictivo basado en modelos (MPC), una breve reseña de aplicaciones industriales y los modelos no lineales más utilizados en estrategias de control predictivo en la actualidad.

El diseño de estrategias FPC T&S basadas en algoritmos de computación evolutiva y su aplicación a series no lineales, son explicadas en el capítulo 3 y 4. Además, se analizan las ventajas y desventajas del uso de cada uno de los algoritmos de solución planteados.

En el capítulo 5 se implementa el mejor algoritmo para la solución de la estrategia de control escogida a la caldera de una planta termoeléctrica de ciclo combinado y la comparación de la utilización de esta estrategia con un sistema de control tradicional. En el capítulo 6 se analizan los resultados de la implementación.

2. Control Predictivo Basado en Modelos No lineales (NMPC)

2.1. Introducción

Las estrategias de Control Predictivo basado en Modelos (MPC) están siendo ampliamente utilizadas en la industria debido a que permiten manejar con éxito problemas de control difíciles tales como plantas con retardo, de fase no mínima, no lineales, que presenten inestabilidad en lazo abierto, con restricciones y combinaciones de las anteriores. También permite un buen manejo de sistemas multivariables. La existencia de paquetes comerciales tales como DMC y Brainwave en la minería (se presentan más ejemplos en la sección 2.2) permiten que sea ampliamente utilizado en la industria. Los parámetros del problema de control predictivo permiten una explicación física fácil de entender. Es posible introducir fácilmente restricciones en las variables de entrada y salida y otro tipo de restricciones fácilmente (por ejemplo, económicas, ambientales, etc.). Como última ventaja de utilización es que permite un ahorro potencial de un 2-6% de los costos totales de operación (Love, 2007) (De Prada, 1997; Sáez *et al.*, 2002).

Cuando se habla de estrategias MPC, no se refiere a un tipo de estrategia en particular sino que agrupa una gran cantidad de estrategias de control que tienen en común los siguientes aspectos (Camacho y Bordons, 1999):

- Cálculo de predicciones en un horizonte definido mediante un modelo dinámico;

- Definición de una trayectoria de referencia futura para las variables controladas;
- Minimización de una función objetivo sujeta a restricciones en las variables del proceso;
- Utilización de un horizonte de control finito y estrategia de horizonte deslizante que implica el cálculo de una secuencia de control que optimiza el comportamiento de la señal de salida de la planta con respecto a una trayectoria definida previamente. Una vez resuelto el problema de optimización, se aplica la primera señal de dicha secuencia y luego la repetición de dicho procedimiento en el siguiente instante de muestreo.
- Se hacen supuestos de la estructura de la ley de control futura.

La metodología de diseño de controladores MPC consiste en los siguientes pasos:

1. Las salidas futuras para un horizonte determinado N , llamado horizonte de predicción, son predichas en cada instante t usando un modelo del proceso. Estas salidas predichas $\hat{y}(t+k/t)$ (el valor de la salida en el instante $t+k$ calculada en el instante t) para $k=1..N$ dependen del conocimiento que se tengan de los valores de la planta hasta el instante t (entradas y salidas pasadas) y sobre las señales de control futuro $u(t+k/t)$, $k=0..N-1$, que son aquellas que van a ser calculadas.
2. Las señales de control futuras son calculadas mediante la optimización de un cierto criterio o función objetivo predictiva para mantener el proceso tan cerca como sea posible de la trayectoria de referencia deseada. Este criterio usualmente toma la forma de una función cuadrática de los errores entre la señal de salida predicha y la trayectoria de referencia y en la mayoría de los casos se añade el esfuerzo de control;
3. La señal de control $u(t)$ es aplicada al proceso.

La función objetivo predictiva que utiliza MPC es de la siguiente forma:

$$J = \underbrace{\sum_{j=N_1}^{N_y} \delta(j) [r(t+j) - \hat{y}(t+j/t)]^2}_{J_1} + \underbrace{\sum_{i=1}^{N_u} \lambda(i) [\Delta u(t+i-1)]^2}_{J_2} \quad (1)$$

donde $\delta(j)$ y $\lambda(i)$ son ponderadores tanto para el término J_1 de seguimiento de referencia como para el esfuerzo de control J_2 ; $\hat{y}(t+j/t)$ son las predicciones que surgen del modelo utilizado, $r(t+j)$ es la trayectoria de referencia deseada¹, $\Delta u(t+i-1)$ es el incremento en la variable manipulada, N_1 y N_y son los horizontes de predicción mínimo y máximo, N_u es el horizonte de control.

Las restricciones surgen a partir del proceso:

- Restricciones a las variables manipuladas:

$$u_{\min} \leq u(t+i-1) \leq u_{\max} \quad \text{con } i = 1 \dots N_u. \quad (2)$$

- Restricciones a los incrementos de las variables manipuladas:

$$\Delta u_{\min} \leq \Delta u(t+i-1) \leq \Delta u_{\max} \quad \text{con } i = 1 \dots N_u. \quad (3)$$

- Restricciones en las variables controladas:

$$y_{\min} \leq \hat{y}(t+j) \leq y_{\max} \quad \text{con } j = N_1 \dots N_y. \quad (4)$$

- Restricciones a los incrementos en las variables controladas:

$$\Delta y_{\min} \leq \Delta \hat{y}(t+j) \leq \Delta y_{\max} \quad \text{con } j = N_1 \dots N_y. \quad (5)$$

Luego, la acción de control que se aplicará a la planta se obtiene de la minimización de la función objetivo (**Ecuación (1)**). Si esta función es de la forma cuadrática planteada, el modelo es

¹ Esta trayectoria debe estar disponible. Puede ser calculada de acuerdo a una ruta óptima o entregada externamente por un operador.

lineal y no hay restricciones, se puede obtener una solución explícita, de otra manera es necesaria la implementación de una optimización numérica para resolver el algoritmo de control.

Es importante notar que MPC ha sido ampliamente utilizado en la industria con buenos resultados (Qin y Badgwell, 2003). A continuación se revisan algunas aplicaciones comerciales de este algoritmo de control.

2.2. Aplicaciones Industriales MPC

Una de las principales fortalezas de las estrategias MPC es la creciente cantidad de implementaciones industriales y el buen desempeño de cada una de éstas.

Qin y Badgwell (2003) reportaron más de 4500 implementaciones industriales de MPC a través del mundo en diferentes áreas de aplicación que incluyen: refinerías, petroquímicas, químicas, papel, minería y metalúrgica, fundiciones, etc.

Algunas de las aplicaciones de paquetes comerciales del tipo MPC mencionados en la literatura se encuentran a continuación (Camacho y Bordons, 2004; Huzmenan *et al.*, 1998; Qin y Badgwell; 2003):

- **AspenTech:** Dynamic Matriz Control (DMC), AspenOne, DMC plus.
- **Hyperion.** DMCplusTM
- **Expertune.** PlantTriage.
- **Adersa:** Identification and Command (IDCOM)
- **Setpoint Inc.:** IDCOM- M (Multivariable)
- **Shell Global Solutions Advanced Control Engineers.:** Shell Multivariable Optimizing Controller (SMOC)
- **Honeywell Profimatics:** Robust Model Predictive Control Technology (RMPCT), ProfitSuite.
- **ABB:** 3dMPC y Expert Optimizer, Optimize IT.
- **Invensys:** Connoisseur.
- **Emerson:** EnTech. DeltaV Predictor.
- **Yokogawa:** APCSuite.
- **Andritz Automation, Universal Dynamics:** Brainwave.

- **Pavilion Technologies:** Pavilion8
- **Capstone Technology:** MACS

A continuación se detallan algunas de estas aplicaciones.

El desarrollo de las estrategias de control MPC en el área industrial comienza en el año 1976 en una conferencia en la que Richalet *et al.* (1976 y 1978) presentaron la aplicación de su software IDCOM (Identification and Command) en la que se implementó una estrategia de control que denominaron MPHIC (Model Predictive Heuristic Control). Esta estrategia consideraba la respuesta al impulso de la planta en la etapa de identificación, permitiendo la inclusión de restricciones en las entradas y salidas.

A principios de los 70s se realizó un desarrollo independiente por ingenieros de Shell Oil con una aplicación inicial en 1973. Cutler y Ramaker (1979 y 1980) presentaron los detalles de un algoritmo de control por matriz dinámica (DMC, Dynamic Matrix Control) en un encuentro de la AIChE (American Institute of Chemical Engineering) en 1979 y en 1980 en la Conferencia de Control Automático. Prett y Gillette (1980) reportan una aplicación de DMC a un reactor de una planta química. El algoritmo DMC utiliza como modelo de la planta la respuesta al escalón de la planta que se obtiene a partir del paquete DMI de identificación, propietario de Aspen. Esta aplicación solo permite un paso en el horizonte de control y necesita correcciones de las variables predichas para evitar el Offset.

Estas estrategias de control fueron el comienzo de un gran desarrollo de aplicaciones industriales de MPC, tales como: QDMC (Cutler *et al.*, 1983) en el que se mejora el algoritmo DMC por medio de aplicar la programación cuadrática para resolver el problema de optimización y además, permite la incorporación de restricciones.

Una aplicación interesante en el área de la minería es la que se implementa en un circuito de molinos de bolas, una aplicación industrial muy conocida para la aplicación de sistemas expertos que permite evaluar nuevos métodos de control debido a sus múltiples acoplamientos y

no linealidades (Chen *et al.*, 2009). La estrategia de control en este caso, consistió en la aplicación de múltiples modelos lineales del tipo DMC obtenidos a partir de diferentes condiciones de operación que son cambiadas a partir de la medición de la dureza del mineral. Los autores llaman a este tipo de estrategia Adaptive DMC (ADMC), siendo en realidad una aplicación del tipo Predictivo Híbrido. La aplicación de este tipo de estrategias en una planta industrial presentó mejoras importantes en comparación con la del DMC tradicional.

En Marusak (2008), se encuentra una implementación de DMC difusa, en la que se utiliza la estructura T&S, en la que los parámetros de las consecuencias están en la forma de respuestas escalón tradicionales del DMC. Este algoritmo fue implementado presentando mejores resultados comparativos con DMC tradicional pero con un mayor esfuerzo computacional.

En la práctica, DMC permite ser utilizado con plataformas como VAX con interfase al Sistema de Control Distribuido (DCS) o correr directamente en nodos de aplicación de algunos DCS.

El paquete comercial IDCOM-M (Grosdidier *et al.*, 1988; Froisy y Matsko, 1990) permite una formulación multivariable.

SMOC (Shell Multivariable Optimizing Controller) (Marquis y Broustail, 1998) implementa un modelo de la planta basado en espacios de estado, modelos para perturbaciones y un filtro de Kalman que estima los estados y perturbaciones de la planta a partir de las salidas medidas. Además, en las nuevas versiones, permite la incorporación de variaciones en la función objetivo, tales como la incorporación de componentes económicas o ambientales.

En la práctica, este paquete permite la implementación en tiempo real por medio de sistemas de tipo supervisor (VAX, Dec-Alpha), o en DCS (Fox - IA) (Process Automation Handbook, Springer).

Honeywell, con su RMPCT (Robust Model Predictive Control Technology) y Aspen, con DMC- plus presentan asimismo en 1995 y 1996, respectivamente, algoritmos que tienen las

siguientes características: interfaces gráficas de usuario basadas en Windows, niveles múltiples de optimización para direccionar objetivos de control priorizados, permiten incluir objetivos económicos en la formulación y se da una consideración directa a la incerteza del modelo. En el caso del RMPCT, se obtiene un modelo de la planta por medio de la aplicación de un paquete identificador propietario en el que se convierte un modelo de respuesta al impulso, derivado de una respuesta escalón, en un modelo de tipo ARMAX. Bassett and van Wijck (1999) utilizan este controlador en una aplicación industrial petrolera en la que se permite la implementación exitosa con 42 variables. En Yoo *et al.* (2006), se encuentra una aplicación a una planta química altamente no lineal en la que se observan buenos resultados de control y permite incorporar objetivos económicos que son alcanzados satisfactoriamente. Honeywell, por medio de su paquete de identificación propietario Profit, permite la utilización de redes neuronales (Parthasarathy *et al.*, 1999). RMPCT implementa una estrategia de control zonal en la que se divide el espacio de solución, y en la que se cambian controladores para diferentes puntos de operación. Para poder realizar esto introduce restricciones suaves en las que cambia entre diferentes penalizaciones que permiten determinar si está dentro del espacio del punto operativo (Qin and Badwell, 2003).

El controlador RMPCT funciona con un módulo de aplicaciones directamente en el DCS Honeywell o en nodos del DCS con conexión a la red de procesos.

El Connoisseur (Labbe *et al.*, 2006), utiliza modelos del tipo ARMAX o FIR derivados de un software propietario de identificación del tipo RLS y de conversión a modelos. Este controlador permite modelar la planta con un modelo no lineal, específicamente, por medio de una Red Neuronal del tipo Radial Basis Function (RBF) en tiempo real por medio del mencionado identificador de tipo FIR.

Este controlador se puede implementar en plataformas que incluyen UNIX y NT en Sun, DEC y Máquinas HP. Cuenta con interfaces a la mayoría de los DCS y PLC existentes.

3dMPC y Expert Optimizer de ABB permiten también la utilización de una estrategia MPC en tiempo real. Estos controladores utilizan modelos fenomenológicos no lineales de las plantas y del tipo híbrido.

El Brainwave (Huzmezan *et al.*; 2002, 2003) es un controlador de tipo supervisor en el que se obtienen los diferentes setpoints de la planta por medio de algoritmos de optimización que corren en tiempo real y son sintonizados offline por medio de un simulador de procesos fenomenológico. Huzmezan *et al.* (2002), utiliza una estrategia de control adaptivo – predictivo en la que la identificación se realiza por medio de representaciones en Series de Laguerre. En Huzmezan *et al.* (2003), se encuentra una aplicación industrial de un reactor batch de PVC (Polyvinil Chloride) en que en la identificación se utilizan funciones discretas de Laguerre y los resultados industriales informan considerables ahorros económicos. Hoy día existen implementaciones de Brainwave en plantas concentradoras de cobre en Chile.

Las aplicaciones industriales más conocidas son el Profit Suite de Honeywell y DMCplus de Aspentech. La más utilizada es AspenOne (DMC) (Bauer and Craig, 2008)

2.3. Modelación Difusa en NMPC

El buen desempeño de los controladores MPC depende principalmente de los modelos utilizados y su capacidad de representar el comportamiento dinámico de los procesos.

Como se vio previamente, los modelos lineales han sido usados ampliamente en aplicaciones industriales y una gran cantidad de trabajos tratan el marco teórico en temas como la estabilidad y robustez de la estrategia. Las formulaciones lineales pueden ser: modelos en espacios de estados, respuesta temporal, impulso y escalón, polinomiales o función de transferencia entre otros.

A pesar del gran desarrollo de las estrategias de MPC lineales y sus aceptables resultados a nivel industrial, es necesario obtener una mejor representación de las no linealidades del proceso utilizando modelos no lineales como son los difusos (Allgöwer *et al.*, 1999).

Los modelos difusos se basan en reglas que permiten incorporar la no linealidad en la representación del sistema.

En aplicaciones de control predictivo no lineal (NMPC) se han utilizado variantes de estos modelos, tales como:

- Difusos relacionales, tanto en su formulación simple como en la adaptiva, (Valente de Oliveira y Lemos, 1994; Wong *et al.*, 2000),
- del tipo Mandami (Nagarajan y Kumar, 2001) y
- del tipo Takagi & Sugeno (T&S) (Skrjanc y Matko, 1994; Sáez *et al.*, 2002) para el cálculo de las predicciones.

2.3.1. Modelos Difusos Relacionales

En la formulación relacional de los modelos difusos se utiliza la siguiente estructura para el cálculo de las predicciones (Valente de Oliveira y Lemos, 1994), (considerando el vector de entradas como $x = (x_1, \dots, x_{m=n_y+n_u}) = (y(t-1), \dots, y(t-n_y), u(t-1), \dots, u(t-n_u))$):

$$y(t) = \Psi^T \Omega \quad (6)$$

donde $\Omega(m \times 1)$ es el vector de parámetros y $\Psi(m \times 1)$ es el vector de entradas difusas, dado por el producto de Kronecker (\otimes) de las entradas individuales difusas, es decir,

$$\Psi = X_1 \otimes X_2 \otimes \dots \otimes X_m \quad (7)$$

Donde

$$A_{m \times n} \otimes B_{p \times q} = \begin{bmatrix} a_{11}b & \dots & a_{1n}b \\ \dots & \dots & \dots \\ a_{m1}b & \dots & a_{mn}b \end{bmatrix}$$

$$A \otimes B = \begin{bmatrix} a_{11}b_{11} & a_{11}b_{12} & \dots & a_{11}b_{1q} & \dots & \dots & a_{1n}b_{11} & a_{1n}b_{12} & \dots & a_{1n}b_{1q} \\ a_{11}b_{21} & a_{11}b_{22} & \dots & a_{11}b_{2q} & \dots & \dots & a_{1n}b_{21} & a_{1n}b_{22} & \dots & a_{1n}b_{2q} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ a_{11}b_{p1} & a_{11}b_{p2} & \dots & a_{11}b_{pq} & \dots & \dots & a_{1n}b_{p1} & a_{1n}b_{p2} & \dots & a_{1n}b_{pq} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ a_{21}b_{11} & a_{21}b_{12} & \dots & a_{21}b_{1q} & \dots & \dots & a_{2n}b_{11} & a_{2n}b_{12} & \dots & a_{2n}b_{1q} \\ a_{21}b_{21} & a_{21}b_{22} & \dots & a_{21}b_{2q} & \dots & \dots & a_{2n}b_{21} & a_{2n}b_{22} & \dots & a_{2n}b_{2q} \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ a_{m1}b_{p1} & a_{m1}b_{p2} & \dots & a_{m1}b_{pq} & \dots & \dots & a_{mn}b_{p1} & a_{mn}b_{p2} & \dots & a_{mn}b_{pq} \end{bmatrix}$$

Donde los X_i son derivadas uno a uno de las entradas no lineales x_i de acuerdo al siguiente procedimiento:

$$X_i = \left[\mathfrak{N}_{i1}(x_i) \cdot \mathfrak{N}_{i2}(x_i) \cdot \dots \cdot \mathfrak{N}_{ic_i}(x_i) \right] \quad (8)$$

donde $\mathfrak{N}_{ij}(\cdot)$ es el j -ésimo conjunto difuso de la i -ésima variable de entrada con c_i conjuntos difusos.

Una modificación a esta representación son los modelos difusos relacionales adaptivos donde se utiliza una representación difusa con autoaprendizaje, que se basa en la **Ecuación (7)**. En esta formulación el controlador utiliza dos modelos difusos relacionales, uno dinámico y otro estacionario, donde la acción de control $u(t)$ se calcula usando una combinación lineal de los resultados de ambos basada en la magnitud de un parámetro de diseño α (Wong *et al.*, 2000).

2.3.2. Modelos Difusos Takagi & Sugeno

La estructura del modelo difuso T&S consiste en el uso de un conjunto de reglas que definirán una salida.

La regla R_i del modelo es del siguiente tipo:

if $y(t-1)$ is A_1^r and...and $y(t-n_y)$ is $A_{n_y}^r$ and $u(t-1)$ is B_1^r and... and $u(t-n_u)$ is $B_{n_u}^r$ (9)

then

$$y_r(t) = a_1^r y(t-1) + a_2^r y(t-2) + \dots + a_{n_y}^r y(t-n_y) + b_1^r u(t-1) + \dots + b_{n_u}^r u(t-n_u) + c^r$$

donde A_i^r y B_i^r son los conjuntos difusos para la regla r , que en el caso de esta tesis son gaussianas que están definidos por dos parámetros: la amplitud y el centro; a_i^r , b_i^r y c^r son los parámetros de las consecuencias de la regla asociados con la variable i e y_r es la salida de la regla r .

Esta estructura de reglas entrega la naturaleza no lineal del modelo. En primer lugar, las premisas de cada regla son no lineales y dependen del tipo de conjunto difuso que se utilice. Estos conjuntos difusos pueden ser gaussianas, triangulares, trapezoidales, etc. Luego, por medio de los conjuntos difusos se define el grado de activación de cada regla, multiplicando los grados de pertenencia de las variables a su conjunto correspondiente. Con los respectivos grados de activación de cada regla se obtiene una suma ponderada de las consecuencias lineales por su grado de activación que es la salida del modelo:

$$y(t) = \sum_{\ell=1}^{n_y} \bar{a}_\ell y(t-\ell) + \sum_{\ell=1}^{n_u} \bar{b}_\ell u(t-\ell) + \bar{c}(t) \quad (10)$$

con

$$\bar{a}_\ell(t) = \sum_{r=1}^R \omega_r(t) a_\ell^r; \quad \bar{b}_\ell(t) = \sum_{r=1}^R \omega_r(t) b_\ell^r; \quad \bar{c}(t) = \sum_{r=1}^R \omega_r(t) c^r$$

donde R es el número de reglas y $\omega_r(t)$ es el grado de activación normalizado de la regla r . Los parámetros de las premisas de las reglas pueden ser obtenidos mediante el uso de un método de clustering difuso (Sugeno *et al.*, 2003), los parámetros de las consecuencias de las reglas del modelo son obtenidas por mínimos cuadrados usando el método de Takagi y Sugeno (Takagi y

Sugeno, 1985)

La no linealidad de la salida del modelo se resume en la siguiente expresión:

$$y(t) = \sum_{\ell=1}^{n_y} \left(\sum_{r=1}^R \omega_r(t) a_\ell^r \right) y(t-\ell) + \sum_{\ell=1}^{n_u} \left(\sum_{r=1}^R \omega_r(t) b_\ell^r \right) u(t-\ell) + \sum_{r=1}^R \omega_r(t) c^r \quad (11)$$

donde los ponderadores de los regresores son altamente no lineales.

2.4. Estrategias de Control Avanzado aplicado a Plantas Termoeléctricas

En la actualidad las estrategias de control avanzado han ganado una gran aceptación lo que se evidencia en el creciente número de aplicaciones de control predictivo a nivel industrial (Qin and Badwell, 2003). Sin embargo, en el contexto general de las plantas en construcción se contempla que en la fase inicial de construcción solo se aplican estrategias de control regulatorio tipo PID. Una vez construida la planta y ya en operación se analizan estrategias de control avanzado, tales como sistemas expertos, control difuso PID, MPC u otras estrategias de control que existen en el mercado.

Las limitaciones que tiene este tipo de estrategias ya se han comentado en el capítulo 1 y 2 del presente trabajo por lo que se hace necesario en la operación de las plantas la incorporación de estrategias de control avanzado para poder mejorar el desempeño de los lazos de control o incorporar restricciones económicas, ambientales o de otro tipo que sean atractivas desde el punto de vista de la empresa. Es así como las estrategias del tipo predictivo supervisor se han planteado como una solución eficiente para estos objetivos.

A continuación se presentan trabajos de control aplicados a plantas termoeléctricas que se muestran en general superiores a las convencionales de tipo PID.

En Hogg y El-Rabaie (1990, 1991) se aplica GPC a una planta termoeléctricas presentando un comportamiento superior a los PIs para diferentes modos de operación. Esto se observó tanto en la reducción de la variabilidad de la respuesta como en la eliminación del error permanente y reducción del esfuerzo de control.

El trabajo de control de una caldera de Manayathra *et al.* (1994) incorpora una modificación en la función de costos de control predictivo. Bentsman *et al.* (1994, 1995) utiliza inicialmente una estrategia de control robusto H_∞ , Minmax con buenos resultados en estabilidad y robustez pero no permite agregar restricciones. En su segunda aproximación utiliza control H_2 que permite incorporar restricciones. Lee, (1995) presenta una estrategia de control difuso PI aplicado a una caldera de planta termoeléctricas. En ésta se utiliza la lógica difusa para el ajuste de los parámetros, con lo que se autoajusta por medio de un algoritmo basado en las variaciones del parámetro proporcional del controlador. Este método presenta una mejora en comparación con respecto al PI convencional con parámetros constantes.

Un sistema experto difuso se introduce por Sánchez *et al.* (1995). Este Sistema Experto disminuye en comparación con PIs la variabilidad de respuesta de las señales controladas. Las reglas del experto provienen de un modelo difuso del proceso obtenido del conocimiento de los operadores del proceso. Este trabajo reduce las oscilaciones provocadas por perturbaciones.

Otra aplicación de estrategias de control es presentada en Zhiteckij *et al.* (1995), donde se aplica una estrategia de tipo adaptivo a una planta termoeléctrica.

Un trabajo posterior de Sánchez *et al.* (1995a) utiliza un paquete comercial de control predictivo (DMC).

En Sáez *et al.* (2000)² se presenta una aplicación predictiva del tipo supervisor que es la base de la aplicación final de esta tesis, ya que presenta la aplicación industrial a una Caldera Recuperadora de Vapor de una Central Termoeléctrica de Ciclo Combinado en la que la identificación se realiza con modelos difusos T-S y se utiliza el nivel predictivo supervisor con una función objetivo que considera aspectos económicos.

² En este trabajo se encuentra una revisión bibliográfica que puede ser consultada para trabajos anteriores al año 2000.

Kobayashi *et al.* (2000) presenta la aplicación de un control supervisor predictivo difuso multivariable a una planta industrial de petróleo, en el que se aplica un control supervisor jerárquico en el que la etapa supervisora entrega los setpoints al sistema predictivo multivariable que luego entrega los setpoint para el nivel regulatorio PID que es aplicado directamente a la planta.

En Bulut *et al.* (2000), se encuentra una aplicación de Control Predictivo a nivel Supervisor en un molino industrial. La primera estrategia considera la aplicación de un control en cascada en el que se calculan los setpoints para el control regulatorio PID. En el segundo caso se modifica la señal manipulada por medio de sumar la señal calculada por el GPC a la entregada por el control PID. Además, se incorporan restricciones.

En Peng *et al.* (2002), se presenta la aplicación de una estrategia NMPC de una planta de potencia del tipo caldera con turbina de 600 MW, en el que la identificación se realiza por medio de modelos MIMO del tipo ARX, donde los parámetros de los regresores son combinaciones no lineales que incorporan exponenciales.

En Tadeo (2002, 2008) se presenta una estrategia de control supervisor predictivo en el que se utiliza el nivel supervisor para entregar las referencias para el nivel regulatorio PID utilizando una función objetivo de tipo regulatoria.

En Uduehi *et al.* (2004) se encuentra una aplicación a un evaporador industrial de un Control Predictivo Supervisor Multivariable que utiliza modelos en espacios de estado.

Una aplicación a la Caldera Recuperadora de Vapor se encuentra en Contreras (2004), donde se utiliza un Controlador Predictivo basado en Modelos Neuronales.

Vinsonneau *et al.* (2005) utilizan una estrategia supervisora jerárquica aplicada a un horno multizona en la que se presentan tres niveles de jerarquías. En el nivel superior se monitorean las señales de salida de la planta de acuerdo al aporte de calor por zona para poder realizar en el nivel

intermedio los ajustes a las señales de referencia para los lazos de control que están en el nivel inferior.

En Zhang *et al.* (2007) se calculan los setpoints por medio de funciones difusas basadas en reglas del tipo Mandami, con éstos se alimenta el nivel regulatorio que es un PID del tipo predictivo. Esta estrategia de control se aplica a una caldera calentada por petróleo.

Sáez *et al.* (2007) presenta una aplicación a una Turbina de Gas de una Central Termoeléctrica de Ciclo Combinado, donde la identificación se realiza por medio de la utilización de modelos difusos T-S y el control es del tipo predictivo supervisor. El problema de optimización no lineal planteado se resuelve por medio de Algoritmos Genéticos. Flores *et al.* (2005) aplica en una planta solar control predictivo basado en optimización difusa.

En Liu and Niu (2008) se aplica una estrategia de control predictivo neuro-difuso, aplicado a una unidad generadora de vapor con domo con calentamiento adicional por petróleo de 160 MW, la modelación es por medio de una linealización en torno a un punto de operación de una red neuronal tipo feedforward. La etapa de control es realizada por medio de la aplicación combinada por la activación difusa de múltiples modelos MPC lineales.

El principal aporte de este trabajo está en la solución del problema de optimización que se plantea al utilizar en la identificación MIMO por medio de modelos difusos T-S de la Caldera Recuperadora de Vapor de la Central de Ciclo Combinado y la aplicación de control predictivo a nivel supervisor. El problema de optimización presenta múltiples óptimos locales por lo que la solución por medio de algoritmos matemáticos tradicionales basados en gradientes no entrega una solución razonable tanto en términos del tiempo de cómputo como en la factibilidad de solución.

La solución heurística planteada está basada en los algoritmos de computación evolutiva que han sido mencionados en los anteriores capítulos, Algoritmos Genéticos, Algoritmos

Genéticos basados en Nichos y PSO. La solución será testeada en el simulador propuesto por Ordys (1994) e implementado por Sáez (2000).

3. Control Predictivo Difuso T&S basado en Algoritmos de Computación Evolutiva

3.1. Introducción

La característica principal que hace deseable la implementación de estrategias de control predictivo difuso (FPC, Fuzzy Predictive Control) es que permite obtener mejores desempeños en plantas no lineales como las plantas termoeléctrica de ciclo combinado. Sin embargo, el alto costo computacional de la resolución del problema de optimización mediante algoritmos convencionales dificulta su uso en tiempo real. Es por eso que en esta sección se propone el uso de algoritmos de computación evolutiva para la resolución del problema de minimización planteado por el control predictivo en un menor tiempo y con un menor costo computacional.

3.2. Planteamiento del Problema

En la teoría de Control Predictivo Generalizado (GPC) (Clarke, 1987) se proporciona una solución analítica al problema de minimización definido en la **Ecuación (1)**. La estrategia de control predictivo no lineal basado en modelos difusos minimiza el mismo criterio en cada iteración usando un algoritmo de optimización no lineal.

A continuación se plantea la estrategia de control predictiva FPC.

La función objetivo está dada por:

$$\underset{\{u(t), \dots, u(t+N_u-1)\}}{\text{Min}} \quad J = J_1 + J_2 \quad (12)$$

donde,

$$J_1 = \sum_{j=N_1}^{N_y} \delta(j) [w(t+j) - \hat{y}(t+j)]^2 \quad (13)$$

$$J_2 = \sum_{i=1}^{N_u} \lambda(i) [\Delta u(t+i-1)]^2 \quad (14)$$

donde $\delta(j)$ y $\lambda(i)$ son los pesos o ponderadores para el comportamiento futuro, $w(t+j)$ es la trayectoria futura de referencia, $\hat{y}(t+j)$ corresponde a la predicción de la variable controlada, $\Delta u(t+i-1)$ es el incremento de las acciones de control futuras, N_1 y N_y son los horizontes de predicción mínimos y máximos, respectivamente, y N_u es el horizonte de control.

En esta tesis, los modelos difusos no lineales T&S son considerados para las predicciones de las variables controladas y para el diseño de estrategias de control predictivo no lineal.

3.2.1. Predictor Difuso T&S

Los modelos difusos T&S han sido utilizados exitosamente para la identificación de sistemas no lineales (Sugeno *et al.*, 2003). La estructura de una regla de este tipo de representación es:

$$\text{if } y(t) \text{ is } A_1^r \text{ and } \dots \text{ and } y(t-n_y) \text{ is } A_{n_y}^r \text{ and } u(t) \text{ is } B_1^r \text{ and } \dots \text{ and } u(t-n_u) \text{ is } B_{n_u}^r \quad (15)$$

then

$$\hat{y}_r(t+1) = a_1^r y(t) + a_2^r y(t-1) + \dots + a_{n_y}^r y(t-n_y) + b_1^r u(t) + \dots + b_{n_u}^r u(t-n_u) + c^r$$

donde A_i^r y B_i^r son los conjuntos difusos para la regla r , a_i^r , b_i^r y c^r son los parámetros de las consecuencias de la regla asociados con la variable i y \hat{y}_r es la salida predicha de la regla r .

La salida del modelo difuso es:

$$\hat{y}(t+1) = \sum_{\ell=0}^{n_y} \bar{a}_\ell y(t-\ell) + \sum_{\ell=0}^{n_u} \bar{b}_\ell u(t-\ell) + \bar{c}(t) \quad (16)$$

con

$$\bar{a}_\ell(t) = \sum_{r=1}^R \omega_r(t) a_\ell^r; \quad \bar{b}_\ell(t) = \sum_{r=1}^R \omega_r(t) b_\ell^r; \quad \bar{c}(t) = \sum_{r=1}^R \omega_r(t) c^r$$

donde R es el número de reglas y $\omega_r(t)$ es el grado de activación normalizado de la regla r . los parámetros de las premisas de las reglas pueden ser obtenidos mediante el uso de un método de clustering difuso (Sugeno *et al.*, 2003), los parámetros de las consecuencias de las reglas del modelo son obtenidas por mínimos cuadrados usando el método de Takagi y Sugeno (Takagi y Sugeno, 1985)

La no linealidad de la salida del modelo se visualiza en la siguiente expresión:

$$\hat{y}(t+1) = \sum_{\ell=0}^{n_y} \left(\sum_{r=1}^R \omega_r(t) a_\ell^r \right) y(t-\ell) + \sum_{\ell=0}^{n_u} \left(\sum_{r=1}^R \omega_r(t) b_\ell^r \right) u(t-\ell) + \sum_{r=1}^R \omega_r(t) c^r \quad (17)$$

La **Ecuación (17)** entrega la estructura que tendrán las predicciones del comportamiento de la planta y que serán las restricciones no lineales del problema de optimización derivado del control predictivo.

3.2.2. FPC- Problema de Optimización

El problema de optimización está definido por la función a minimizar que es la función objetivo predictiva y las restricciones no lineales que dependen del modelo difuso, además de las restricciones que se pudieran establecer a las variables involucradas.

Es necesario predecir las variables controladas mediante el cómputo de los siguientes predictores difusos multipaso (Babuska *et al.*, 1999):

$$\hat{y}(t+j) = \sum_{\ell=1}^{n_y} \bar{a}_\ell(t+j) \hat{y}(t+j-\ell) + \sum_{\ell=1}^{n_u} \bar{b}_\ell(t+j) u(t+j-\ell) + \bar{c}(t+j) \quad (18)$$

Con

$$\bar{a}_\ell(t+j) = \sum_{r=1}^R \omega_r(t+j) a_\ell^r; \bar{b}_\ell(t+j) = \sum_{r=1}^R \omega_r(t+j) b_\ell^r; \bar{c}(t+j) = \sum_{r=1}^R \omega_r(t+j) c^r$$

$$\omega_r(t+j) = f_r(\hat{y}(t+j-1), \dots, \hat{y}(t+j-n_y), u(t+j-1), \dots, u(t+j-n_u))$$

donde f_r es una relación no lineal evaluada usando el grado de activación de la regla difusa r .

En este planteamiento se utiliza la predicción $\hat{y}(t+j-1)$ para obtener $\hat{y}(t+j)$, y este procedimiento se repite hasta $t+N_y$.

Este problema de optimización cuadrático sujeto a las restricciones no lineales definidas por los predictores difusos debe ser resuelto mediante métodos de optimización no lineal. Las variables de optimización están dadas por la secuencia de acciones de control futuras, es decir, $\{u(t), \dots, u(t+N_u-1)\}$ y luego se aplica a la planta solamente la primera acción de control $u(t)$ al proceso mediante un horizonte deslizante donde la información es actualizada en el siguiente paso.

Los predictores difusos resultantes son no lineales, particularmente para sistemas multivariables. Este problema planteado no puede ser resuelto por métodos de optimización no lineal convencionales en un tiempo razonable y con un buen desempeño. Por esta razón, se propone el uso de nuevos métodos de optimización basados en algoritmos de computación evolutiva que han presentado un desempeño adecuado en otras tareas de optimización altamente no lineales entregando buenas soluciones en un menor tiempo computacional.

A continuación, se presentan algunos algoritmos de control convencionales y los propuestos basados en computación evolutiva.

3.3. Solución a FPC: Algoritmos de Optimización

La solución al problema de optimización derivado de FPC requiere la utilización de métodos no lineales. En esta sección, se describen algunos algoritmos de optimización no lineal convencionales tales como Newton y Levenberg-Marquardt y los algoritmos propuestos para la solución del problema de control predictivo: algoritmo genético simple y por nichos (SGA, Simple Genetic Algorithm; NGA, Niching Genetic Algorithms) y Optimización por Enjambre de Partículas (PSO, Particle Swarm Optimization) son aplicados para solucionar el problema que proviene del diseño de estrategias FPC.

3.3.1. Algoritmos de Optimización Convencional

El problema de optimización planteado por FPC necesita una acción de control que sea calculada en tiempo real y de manera precisa y que permita ser calculada con las capacidades de cómputo existentes hoy día.

Es por esto que las soluciones basadas en gradiente, en general, muy lentas, han incorporado modificaciones que han disminuido el tiempo de cómputo. Algunas modificaciones incluyen las basadas en Gradiente Conjugado, Algoritmos de Quasi – Newton y Levenberg Marquardt.

Para obtener una explicación en detalle de los algoritmos convencionales, se puede revisar el trabajo de Dennis and Schnabel (1983) en el que se basan las siguientes dos subsecciones.

3.3.1.1. *Métodos de Quasi - Newton*

En este método se presume que los términos de la expansión mayores a 2do orden en series de Taylor son despreciables. Queda de la siguiente manera:

$$f(x(k)) \approx f(x(k-1)) + Jac(x(k-1))^T \Delta x + \frac{1}{2} \Delta x^T H(x(k-1)) \Delta x \quad (19)$$

El objetivo de optimización es encontrar el paso Δx que asegure que x es óptimo.

Jac y H son el Jacobiano y el Hessiano respectivamente.

Según este método la solución obtenida luego de diferenciar para obtener el mínimo resulta en lo siguiente:

$$\Delta x = \underbrace{-J(x(k-1))}_{\text{Paso de Búsqueda}} \cdot \underbrace{H(x(k-1))^{-1}}_{\text{Dirección de Búsqueda}} \quad (20)$$

En este término se representan el paso y dirección de búsqueda.

Una de las complicaciones principales que tiene este algoritmo se presenta en la inversión del Hessiano que es un procedimiento complejo y difícil de computar por el tamaño de la matriz que se debe invertir.

Una solución que se puede presentar a este problema es no calcular las segundas derivadas o aproximar el inverso del Hessiano por un término más simple. Estos métodos se denominan de Quasi – Newton, siendo uno de los más utilizados el de Broyden, Fletcher, Goldfarb y Shanno (BFGS) (Dennis and Schnabel, 1983).

3.3.1.1.i. Aplicación a FPC

La aplicación del algoritmo recursivo de Newton se presenta en la **Figura 1**.

Se define $x(t) = [y(t) \quad \dots \quad y(t + N_y) \quad u(t) \quad \dots \quad u(t + N_u)]$.

La condición de término puede estar dada por alguna cantidad de iteraciones u otro criterio de diseño del controlador. Luego, una vez cumplida la condición de término se aplica $u(t)$ al proceso.

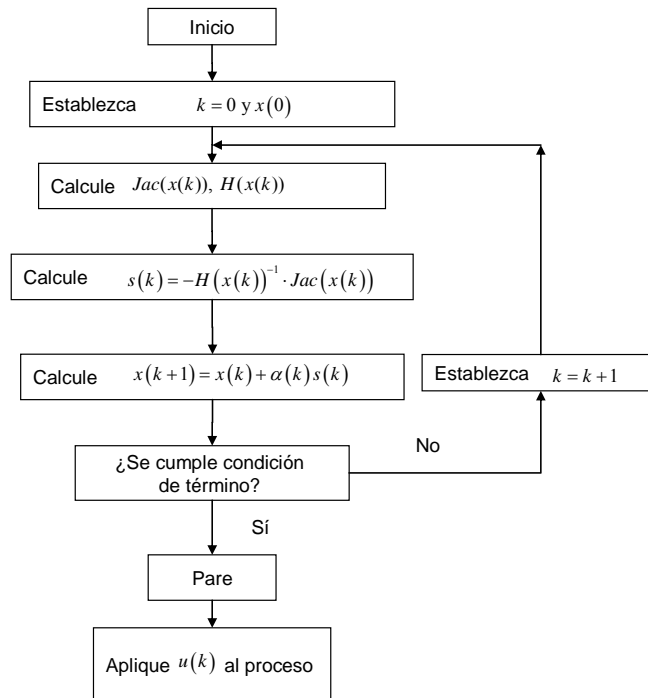


Figura 1. Método de Newton Recursivo aplicado a FPC

3.3.1.2. *Levenberg Marquardt*

En este método se obtiene de la siguiente manera: primero se aproxima el Hessiano a la matriz identidad por lo que la **Ecuación (20)** queda de la siguiente manera:

$$\Delta x = -H(x(k-1))^{-1} J(x(k-1)) = -J(x(k-1)) \quad (21)$$

De la **Figura 1**, α es un parámetro de diseño.

A partir del concepto anterior, se modifica la dirección de descenso. Para esto se vuelve a incorporar el Hessiano sumándole la identidad por un factor escalar β , variante en el tiempo, que permite dominar con un valor alto al inicio de las iteraciones para luego ir disminuyendo y permitir que domine el Hessiano.

$$\Delta x = -\left(H(x(k-1)) + \beta \cdot I\right)^{-1} J(x(k-1)) \quad (22)$$

3.3.1.2.i. Aplicación a FPC

Se puede definir un algoritmo de optimización de la siguiente manera por medio de L-M recursivo en la **Figura 2**.

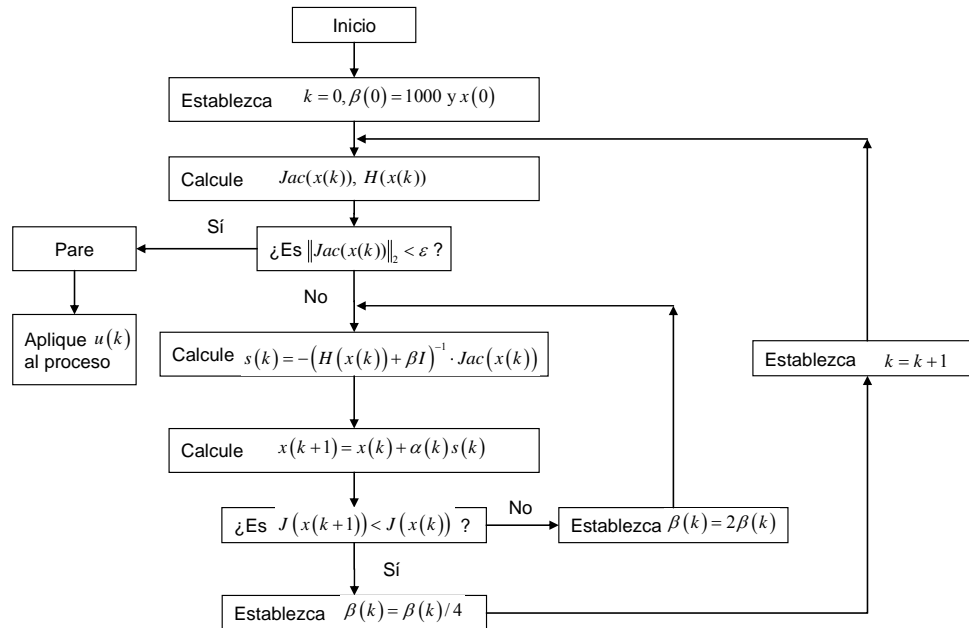


Figura 2. Levenberg Marquardt Recursivo aplicado a FPC

3.3.2. Algoritmos de Optimización Propuestos

En la presente tesis se propone una metodología de diseño de estrategias FPC basadas en algoritmos de computación evolutiva. Este tipo de algoritmos son relativamente recientes, de hecho el término fue inventado en 1991 y representa un esfuerzo por agrupar investigaciones que tuvieran como denominador común la simulación computacional de algunos procesos que se dan en los organismos vivos.

Como algoritmos evolutivos se conocen todos los que tienen algunas características en común:

- Están basados en una población
- A través de las iteraciones del algoritmo se realiza una búsqueda estocástica dentro del espacio de soluciones factibles

- Se utilizan operadores genéticos para determinar las nuevas generaciones de la población.

En particular, dentro de este tipo de algoritmos se encuentran los algoritmos genéticos (Holland, 1965; Schwefel, 1965), estrategias evolutivas (Schwefel, 1995; Rechenberg, 1994) y programación evolutiva (Fogel *et al.*, 1966), que cuentan con características en común, a saber: tienen un proceso de reproducción, variación aleatoria, competencia y selección de individuos (dentro de las soluciones factibles) que están compitiendo dentro de una población. Para una revisión de los conceptos de GA y NGA se puede consultar el trabajo de Estévez (1997).

Otro algoritmo de computación evolutiva es la optimización por enjambre de partículas, (PSO, Particle Swarm Optimization) (Kennedy y Eberhart, 2001), método que ha sido desarrollado como un algoritmo de optimización eficiente. Éste fue inspirado en el comportamiento social de humanos, animales e insectos, como por ejemplo la optimización en un espacio multidimensional de búsqueda de bandadas de aves y cardúmenes de peces.

3.3.2.1. Algoritmos Genéticos

Los algoritmos Genéticos son algoritmos de búsqueda que surgieron a partir de los intentos de imitación de procesos biológicos mediante computadores que se hicieron a principios de los años 1950s (Goldberg, 1989). Esto dio lugar a la investigación realizada por John Holland (1965, 1992) en la Universidad de Michigan que permitió desarrollar los fundamentos y la teoría que se conoce hoy día. Este tipo de algoritmos fueron desarrollados como modelos de procesos de adaptación.

El concepto que subyace tras el mecanismo de búsqueda es la herencia genética. Este permite realizar una búsqueda multidireccional en la que cada individuo de la población es una solución posible de un problema de búsqueda y optimización representado por un cromosoma con sus respectivos genes que se modifica mediante operadores genéticos a través de las generaciones.

Este tipo de algoritmos permite realizar una búsqueda que permite la diversidad y la explotación de los mejores individuos.

A continuación, se analizan los parámetros y operadores que utilizan los algoritmos genéticos.

3.3.2.1.i. Representación o codificación de variables

La representación o codificación de los valores para la variable x fue realizado originalmente mediante una tira binaria que permitía, según el largo de bits, expresar la precisión de la solución que se busca.

En la actualidad, se puede realizar una codificación binaria con un largo opcional de bits y también la codificación mediante números reales en un intervalo. En la **Figura 3** se muestra la codificación aplicada a un problema de MPC.




Figura 3. Codificación para GA

3.3.2.1.ii. Tamaño de la Población

El tamaño de la población es uno de los parámetros más influyentes en el peso computacional del algoritmo, además de la rapidez de su convergencia.

Se inicia el algoritmo con un número de individuos moderado que permita obtener un punto de partida para la optimización y luego se aumenta el tamaño de la población para tener mejores resultados. Desde este punto de vista se puede aumentar hasta el infinito el tamaño de la población, con el correspondiente costo computacional asociado, sin embargo, la curva de desempeño del algoritmo en algunos casos tiene una saturación en su comportamiento.

En problemas que responden a dicha curva de saturación se puede generar un criterio de selección del tamaño de acuerdo al punto en que comience el desempeño a estancarse de acuerdo al valor de la función de fitness, del tiempo o espacio computacional.

La inicialización de la población es realizada estocásticamente dentro del intervalo de diseño de la codificación, es decir, en el espacio de las soluciones factibles para la resolución del problema que se ha planteado. Existe también la posibilidad de inicializar la población mediante una mixtura de individuos elegidos estocásticamente y algunos que sean determinísticos para mejorar el desempeño del algoritmo.

La estrategia de elección del tamaño de individuos inicial para cada instante de optimización en este trabajo consiste en inicializar los individuos en una estructura mixta, es decir, un porcentaje se elegirá aleatoriamente y otro porcentaje será seleccionado determinísticamente.

3.3.2.1.iii. Cálculo de la Función de Fitness o Adaptación

La función de *fitness* es la función que permite determinar el nivel de adaptación de los individuos a la resolución del problema que se ha planteado.

El cálculo del *fitness* es simple conceptualmente, sin embargo, la implementación y definición de la función de *fitness* es relativamente compleja debido a que debe ser planteada de tal manera que dicha función permita realizar una búsqueda que sea eficiente en el espacio de posibilidades.

Se presenta un inconveniente en el uso de una función de *fitness* definida en un rango real, puesto que pueden generarse valores de *fitness* muy altos en comparación con los valores menores de éste, provocándose una explotación de un área que puede contener un mínimo local. Este inconveniente se soluciona utilizando torneo.

Las soluciones a dicho problema son: *scaling* y *ranking*. En el primer caso se toma en cuenta la historia reciente de la población y se asignan los valores del *fitness* sobre la base de

comparación de desempeño de los individuos al promedio reciente de la población. Si el GA está optimizando una función, entonces el *scaling* envuelve la mantención de un registro de los valores mínimos de *fitness* en las últimas generaciones definidas por una ventana de tiempo. Es decir, si el intervalo inicial va desde cero a algún valor y en una generación posterior se presenta un valor mínimo de *fitness* que sea mayor a cero, se establece la linealización a partir de este valor mínimo y el resto de los *fitness* de esa generación deben ser asignados en base a la distancia a ese “piso” o equiespaciamiento. En el caso de la utilización de ranking, se define un intervalo de variación equiespaciado, donde cada *fitness* es asociado a estos puntos en el intervalo de acuerdo a su mayor valor de *fitness*.

En general en el caso del planteamiento de un problema FPC en esta tesis se utilizará como función de *fitness* la **Ecuación (12)**.

3.3.2.1.iv. *Métodos de Selección*

Una vez evaluado el *fitness*, la población de la siguiente generación debe ser capaz de retener las mejores características de la actual y permitir la transmisión de éstas. Para esto se debe buscar un mecanismo que permita discriminar dentro de la población actual los mejores individuos para realizar la explotación de estas características y mantener algunos del resto de individuos que permitan realizar la exploración del espacio de búsqueda.

Existen bastantes métodos de selección en la actualidad debido al creciente estudio de este tipo de algoritmos, sin embargo, nos concentraremos en algunos de ellos:

- Basados en rango: este mantiene un porcentaje de la población para la siguiente generación. Se realiza un ordenamiento por *fitness* y se eliminan los peores que son sustituidos por la descendencia de alguno de los mejores con individuos “normales” de la población. Muestreo Estocástico Universal (SUS, Stochastic Universal Sampling) y Muestreo de rueda de ruleta (RWS, Roulette Wheel Sampling).

- Torneo: Se escoge aleatoriamente un número de individuos de la población, el que tiene la puntuación mayor se reproduce, reemplazando su descendencia al que tiene una menor puntuación.

En el método RWS se crea una rueda de ruleta que se forma a partir del valor de *fitness* que es proporcional al ángulo que ocupa en ésta. Luego, se realiza un muestreo aleatorio mediante un puntero que selecciona individuos de acuerdo a su proporción de la rueda que se forma, es decir, un individuo mejor adaptado puede seleccionar más de un individuo para la siguiente generación.

SUS trata de evitar que los individuos mejor adaptados copen esta rueda de ruleta mediante la utilización de punteros múltiples equiespaciados que seleccionan los padres para la siguiente generación. La utilización de p múltiples punteros permite escoger en cada “lanzamiento” a varios individuos en la rueda en distintos puntos lo que asegura la permanencia de individuos menos adaptados que el que está copando un gran ángulo en la rueda.

3.3.2.1.v. Crossover o Reproducción

Consiste en el intercambio de material genético entre dos individuos. Este tipo de operador genético es muy utilizado y llega a ser una característica diferenciadora ya que existen muy pocos algoritmos de computación evolutiva que no posean un tipo de reproducción.

En la aplicación de este operador se escogen aleatoriamente dos miembros de la población y comparten material genético de acuerdo al tipo de reproducción que se este realizando. Si es crossover de un punto, se escoge un punto de cruza en el que se intercambian los materiales genéticos de los padres para formar dos descendencias con las mitades de este material tal como se aprecia en la **Figura 4**.

Existen otros tipos de reproducción, tales como la de 2 o n puntos en que se escogen múltiples puntos de intercambio de material genético para la formación de la descendencia.




Figura 4. Reproducción de un punto

3.3.2.1.vi. *Mutación*

Este tipo de operador genético contribuye a la diversidad genética de la especie. La mutación se realiza a una pequeña proporción de la población total en la que se altera el cromosoma solo en un gen que genera una descendencia mutada como en la **Figura 5**.




Figura 5. Mutación

El que los algoritmos genéticos puedan manejar bien el problema de mínimos locales lo ha hecho atractivo en una gran cantidad de problemas de optimización. Particularmente, en la formulación del control predictivo se han hecho implementaciones que han entregado buenos resultados de desempeño en comparación con otras estrategias.

3.3.2.1.vii. *Aplicación a FPC*

Los GAs han resultado ser una herramienta muy utilizada para solucionar problemas de optimización predictiva muy complejos y altamente no lineales con buenos resultados (Onnen *et al.*, 1997; Bouani *et al.*, 2006; Yuzgec *et al.*, 2006; Sáez *et al.*, 2008)

En particular, GAs aplicados a FPC han tenido un muy buen desempeño. En Van Sy *et al.*(2008) se encuentra un desarrollo de FPC Takagi Sugeno aplicado a un sistema benchmark. En Causa *et al.* (2008) y Núñez *et al.* (2009), se utilizan los algoritmos genéticos como una eficiente herramienta para solucionar el problema de control predictivo híbrido difuso. Una modificación difusa de los algoritmos genéticos (FPA) se presenta en Liu *et al.*(2008), en la que se plantea un problema FPC basado en FPA entregando mejoras tanto en la precisión como en el tiempo de cómputo. Gyun Na *et al.* (2006), presentan una aplicación de FPC T&S en la que se aplican GAs en la etapa de optimización a una planta nuclear con satisfactorios resultados. En Sarimveis y Bafas (2003) se utiliza una modificación de modelos difusos utilizando GAs en la optimización. Milla *et al.* (2008) presenta una aplicación industrial de una planta termoeléctrica de FPC-GA a nivel supervisor que es solucionada eficientemente por GAs.

La aplicación de GA que se utilizará en este trabajo para el diseño de un controlador FPC se encuentra en la **Figura 6**.

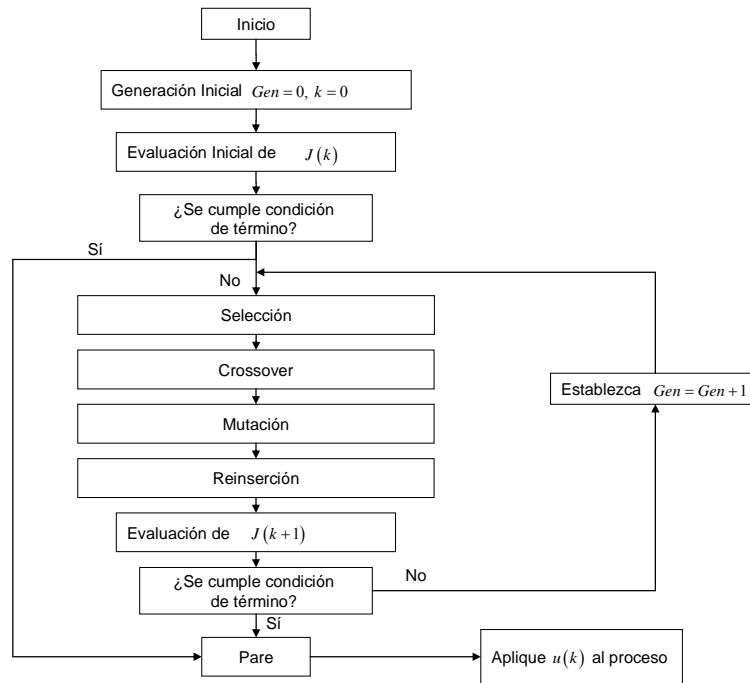


Figura 6. GA aplicado a FPC

Este algoritmo FPC-GA se inicia con la codificación del vector de variables manipuladas como se ve en la **Figura 3**. Esta codificación puede ser en números binarios o reales. Luego, se crea la primera generación de individuos, que puede ser enteramente estocástica o en parte elegida determinísticamente. Una vez elegida la primera población de individuos, se evalúa por primera vez la función de *fitness* de FPC (**Ecuación 12**) y se verifica la condición de término que puede ser por número de generaciones o por valor de la función, si es así, se aplica $u(k)$ al proceso. Si es que no se cumple dicha condición, se realiza la selección de individuos por medio de RWS o SUS para que sean padres de la siguiente generación. Una vez escogidos los individuos padres, se les aplica el operador *crossover* y luego la mutación obteniéndose sucesivamente dos poblaciones de hijos, una primera por reproducción y a partir de esta una mutada. Se evalúan sus *fitness* como criterio para realizar una reinserción de padres o hijos. Una vez finalizado este procedimiento se incrementa el valor del contador de generaciones y se vuelve a verificar el cumplimiento de la condición de término. Finaliza el algoritmo cuando se cumple

esta condición y se aplica solo el valor de la primera componente del vector de variables manipuladas $u(k)$ a la planta.

3.3.2.2. NGA: *Deterministic Crowding*.

NGAs realizan una búsqueda eficiente en el espacio de soluciones factibles mediante particionarlo y definir grupos de individuos organizados en nichos o vecindades del espacio.

En particular *Deterministic Crowding* (DC) (Mahfoud, 1995) es un algoritmo de nichos que los crea y mantiene mediante el reemplazo de los elementos de la población de individuos similares. En DC los individuos “hijos” compiten en un torneo con sus “padres”.

Los GAs (Holland, 1992), tienen limitaciones para manejar funciones multimodales debido al tamaño finito de la población y a los errores estocásticos acumulados. Los métodos de nichos producen una subdivisión del espacio en nichos y la población en especies de individuos, a través de la reducción de la competencia entre los puntos distantes en el espacio de búsqueda.

Se utiliza la distancia de Hamming entre dos individuos:

$$d_{ij} = d(s_i, s_j) \tag{23}$$

donde s_i y s_j son las tiras genotípicas codificadas.

El algoritmo de FPC basado en DC es el siguiente:

1. Se concatenan y codifican las N_u componentes del vector de control en números binarios.
2. Se seleccionan aleatoriamente dos padres (p_1, p_2) de la población, sin reemplazo.
3. Se aplica el operador de *crossover* para obtener dos hijos (c_1, c_2).
4. Se aplica el operador de mutación a c_1 y c_2 y se obtienen c_1' y c_2' .
5. Se utiliza una medida de distancia (**Ecuación (23)**), para aplicar la siguiente regla de reemplazo:

$$\begin{aligned}
& \text{if } [d(p_1, c_1') + d(p_2, c_2')] \leq [d(p_1, c_2') + d(p_2, c_1')] \\
& \quad \text{if } f(c_1') < f(p_1) \quad p_1 = c_1' \\
& \quad \text{if } f(c_2') < f(p_2) \quad p_2 = c_2' \\
& \text{else} \\
& \quad \text{if } f(c_2') < f(p_1) \quad p_1 = c_2' \\
& \quad \text{if } f(c_1') < f(p_2) \quad p_2 = c_1'
\end{aligned} \tag{24}$$

donde f es la función objetivo predictiva que se desea minimizar.

6. Cuando se cumpla la condición de término (iteraciones, tolerancia) el algoritmo para y se obtiene la secuencia de control futuro. Se aplica al proceso solamente $u(k)$.

3.3.2.2.i. Aplicación a FPC

La utilización de NGA en el diseño de una estrategia de control predictivo difuso es similar a la de los GAs. En Solís *et al.* (2006), se encuentra una aplicación FPC-NGA con buenos resultados tanto en la precisión de la solución como en el tiempo computacional en una aplicación del tipo benchmark.

El diagrama de bloques es el siguiente:

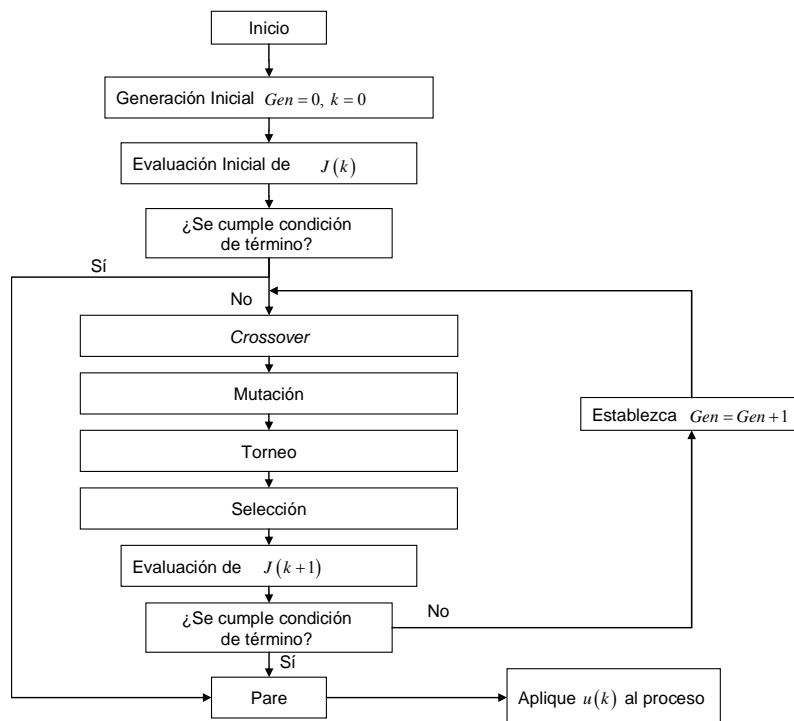


Figura 7. FPC-NGA

3.3.2.3. Algoritmo por Enjambre de Partículas (PSO)

El algoritmo PSO incorpora dos conceptos fundamentales a su funcionamiento: un término social y uno cognitivo.

En el caso del término social se permite que el grupo de partículas que resultan de una optimización en el instante $t-1$, “recuerden” el mejor valor del grupo y el resto de las partículas utilice esa información para su movimiento en el instante $t+1$.

3.3.2.3.i. Algoritmo PSO original

Este Algoritmo consiste en los siguientes pasos:

1. Inicializar una población de partículas con posiciones y velocidades aleatorias en espacio D-dimensional.
2. Para cada partícula, evaluar la función de fitness en D variables
3. Comparar el fitness actual de cada partícula con el fitness de su mejor posición anterior, pbest. Si el valor actual es mejor que el de pbest, entonces hacer pbest = valor actual, y $p_i = x_i$, i.e., la localización actual pasa a ser la mejor hasta el momento.

Identificar la partícula en la vecindad con la mejor tasa de éxito hasta el momento, y asignar su índice a la variable g.

4. Cambiar la velocidad y posición de la partícula de acuerdo a las ecuaciones (para cada dimensión d):

$$\begin{aligned}v_{id}(t+1) &= v_{id}(t) + \varphi_1(p_{id} - x_{id}(t)) + \varphi_2(p_{gd} - x_{id}(t)) \\x_{id}(t+1) &= x_{id}(t) + v_{id}(t+1)\end{aligned}\tag{25}$$

En este algoritmo se contempla un análisis de los parámetros relevantes como son: $V_{\text{máx}}$ y φ .

$V_{\text{máx}}$: este parámetro está relacionado con v_{id} que limita la velocidad de variación y que incide en la posibilidad de explosión del algoritmo. Si este parámetro no está acotado se puede presentar este problema mencionado que se denomina explosión que envía al algoritmo fuera de la región de interés.

φ = este es una ponderación entre los parámetros cognitivos y sociales del algoritmo y se denomina parámetro de aceleración que es un parámetro que permite determinar el tipo de trayectoria que sigue la partícula. φ es aleatorio en un rango.

Con la variación de φ se establece la frecuencia y amplitud con que las partículas realizarán una oscilación en torno al óptimo.

Otros temas de importancia que surgen son la explosión y la convergencia. En estos temas se introducen dos parámetros de interés como son los coeficientes de inercia y de contracción que pasan a ser descritos a continuación.

3.3.2.3.ii. *Modificaciones al Algoritmo PSO Original: Convergencia.*

Coefficiente de Contracción, χ : Se incorpora por Clerc (Clerc *et al.*, 1999) un coeficiente de contracción en la fórmula de velocidad. Se tiene:

$$\begin{aligned} v(t+1) &= \chi \left(v(t) + \varphi_1 (p_i(t) - x(t)) + \varphi_2 (p_g(t) - x(t)) \right) \\ x(t+1) &= x(t) + v(t+1) \end{aligned} \quad (26)$$

Los valores recomendados por Clerc (1999) son los siguientes:

$$\begin{aligned} \varphi_{\max} &> 4 \\ \kappa &\in]0, 1[\\ \chi &= \frac{2\kappa}{\varphi - 2 + \sqrt{\varphi^2 - 4\varphi}} \end{aligned} \quad (27)$$

se definen como valores comúnmente usados $\varphi_{\max}=4.1$ y $\kappa=1$ que entrega un $\chi \approx 0.73$.

Este método hace que la partícula converja en el tiempo, es decir, que disminuya la amplitud de las oscilaciones de la partícula individual. Cuando $\kappa=1$ la convergencia es suficientemente lenta para permitir una exploración completa antes de la convergencia.

Coefficiente de Inercia: Shi y Eberhart (1998) incorporaron un coeficiente o peso de inercia w , que se aplica como sigue:

$$\begin{aligned}v(t) &= \omega v(t-1) + \varphi(p - x(t-1)) \\x(t) &= x(t-1) + v(t)\end{aligned}\tag{28}$$

Un coeficiente de inercia distinto de cero, introduce una preferencia de que la partícula continúe moviéndose en la misma dirección que en la iteración previa, es decir, que mantenga la inercia del algoritmo. Un peso de inercia grande facilita la búsqueda global, mientras que un peso de inercia pequeño facilita la búsqueda local. La introducción del peso de inercia elimina el requerimiento de escoger cuidadosamente una velocidad máxima V_{max} .

Como w y φ afectan a los cambios de velocidad, es posible prevenir la explosión y controlar la convergencia seleccionando valores apropiados de estos parámetros. Usualmente se implementa un annealing del coeficiente de inercia que disminuye en el tiempo, típicamente de 0.9 a 0.4, con $\varphi_{máx} = 4$. El efecto del coeficiente que decrece en el tiempo es estrechar la búsqueda, induciendo un cambio del modo exploratorio al modo de explotación. Ni el coeficiente de inercia con valores apropiados ni los modelos de contracción requieren de una cuidadosa selección del parámetro V_{max} . Basta fijar el parámetro V_{max} en X_{max} , en el rango dinámico de cada variable en cada dimensión.

El coeficiente de inercia decreciente en el tiempo no puede recuperar el modo exploratorio una vez que está en el modo de explotación. Pero con un “esquema de enfriamiento” (annealing) bien escogido el método puede ser efectivo. La experiencia indica que incluir V_{max} con el coeficiente de contracción es bueno y tiene poca carga computacional.

Matemáticamente si se escoge $w = \chi$, $\varphi = \varphi_1 + \varphi_2 > 4$, entonces ambos modelos son equivalentes. Es decir el modelo de coeficiente de contracción es un caso particular del modelo de coeficiente de inercia.

PSO se ha destacado por su buen manejo de problemas multivariados y altamente no lineales por lo que en el último tiempo se han desarrollado una gran serie de trabajos que tratan de optimizar su desempeño o encontrar aplicaciones en las que ocupar este optimizador. Una de las modificaciones que se han reportado en la literatura es el EPSO (Evolutionary Particle Swarm Optimization) que es un método híbrido entre las estrategias optimizantes de tipo evolucionarias y PSO. (Miranda *et al.*, 2002, Miranda *et al.*, 2005, Win, N., 2008). Miranda *et al.* (2002), introduce una variación al algoritmo PSO en la que se agregan la replicación, reproducción, evaluación y selección al algoritmo original. Win (2008) compara ambas estrategias encontrando mejoras al algoritmo inicial. Mori *et al.* (2008) presenta un híbrido entre PSO y TS (Tabu Search)(Glover, 1989) en el que se utilizan ambos algoritmos en dos niveles, TS en el inicio y luego la estrategia EPSO. Este algoritmo, presenta un buen desempeño en un problema real de operación de sistemas de potencia. Dehuri *et al.* (2009) presenta una muy buena revisión del estado del arte del algoritmo PSO, PSO multiobjetivo y además presenta una variación en la que se aplica PSO con Pareto multiobjetivo (Moore and Chapman, 1999; Ray and Liew, 2002; Fieldsend and Singh, 2002) y PNN (Polynomial Neural Networks) (Das, 1995; Nicolaev and Iba, 2006). Este trabajo muestra como en cuatro problemas de clasificación clásico se logran consistentemente mejoras tanto en la precisión como en la simplicidad del algoritmo. Otra modificación interesante se encuentra en Kazemir *et al.* (2008), en la que se utiliza PSO multi agente, donde las partículas forman enjambres que se pueden organizar en dos topologías simples la estrella-estrella y la anillo-anillo, en la que las partículas se actualizan en cada instante de iteración de la manera tradicional del PSO pero la información del mejor la obtienen además de las adyacentes de acuerdo a la topología elegida. Esta estrategia se probó en el diseño de estabilizadores de sistemas de potencia, presentando muy buenos resultados en diferentes condiciones de operación.

Existen otras modificaciones al algoritmo original PSO, tales como GA-PSO, EPSO, DPSO y otras que son explicadas en profundidad en del Valle *et al.* (2007).

3.3.2.3.iii. Aplicación a FPC

La implementación de PSO en el diseño de una estrategia de control predictivo difuso es similar a la de los algoritmos genéticos. En Coelho (2005) se presenta un controlador predictivo basado en modelos lineales recursivos donde el problema de optimización es resuelto mediante PSO. Además se describe un buen desempeño de este algoritmo en comparación con los GAs y métodos del tipo Quasi – Newton. Wang *et al.* (2005) describe un controlador predictivo basado en PSO y mediante la utilización de modelos de redes neuronales del tipo RBF (Radial Basis Function) donde se obtienen resultados levemente superiores a los GAs y a un método de Quasi – Newton. En Lee *et al.* (2007), se utiliza PSO en la etapa de optimización de un controlador predictivo modificado aplicado a una Planta de Potencia. La planta fue identificada mediante modelos neuronales.

En Zhixiang *et al.*(2008), se presenta una modificación a PSO auto adaptiva expandida en la que el término peso de inercia varía de acuerdo a una expresión. Esta modificación fue probada en un benchmark presentando mejores resultados que el PSO original y GA, también se muestra que PSO es superior a GA. En Song *et al.*(2007), se presenta otra modificación a PSO aplicada a control predictivo neuronal, en la que utilizan series caóticas para determinar la velocidad de la partícula. Jin y Su (2008) utilizan una red neuronal recurrente que adapta sus parámetros en cada instante de optimización y resuelven la optimización por medio de PSO. En Solís *et al.* (2006) se realiza una comparación de las tres estrategias presentadas en esta tesis aplicadas a una serie benchmark, presentando PSO resultados superiores a NGA y GA.

El algoritmo FPC-PSO a utilizar en esta tesis se muestra en la **Figura 8**.

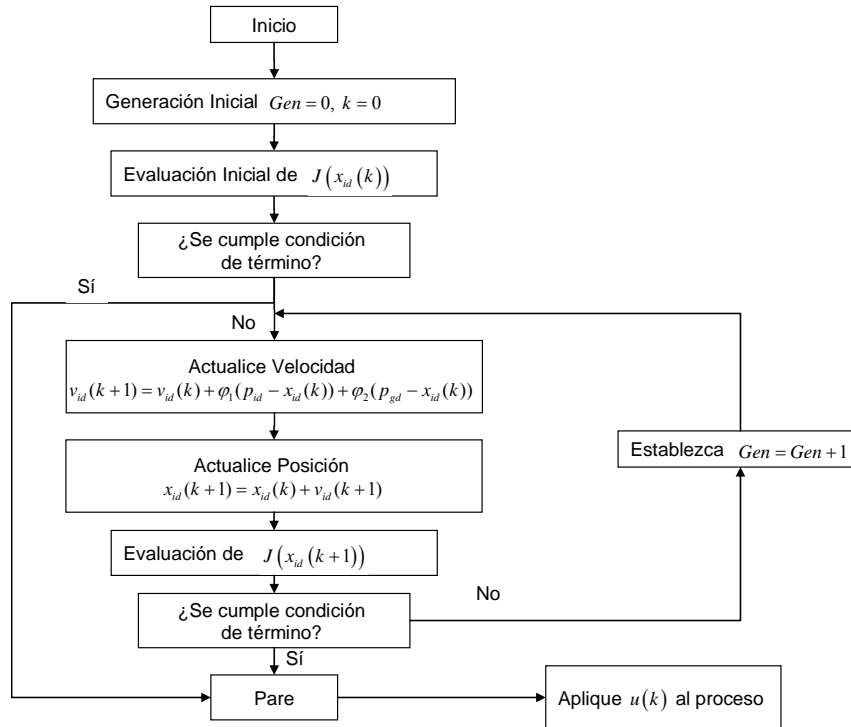


Figura 8. FPC -PSO

Tal como se muestra en este procedimiento se inicializa el algoritmo con la concatenación de las señales manipuladas formando el vector x de partículas. Estas partículas se evalúan por primera vez en la función objetivo de la **Ecuación (12)**. A continuación, se verifica si se cumple la condición de término del algoritmo que puede ser por cantidad de iteraciones o valor de función objetivo. Si se cumple, se aplica $u(t)$ al proceso. En caso contrario, se actualiza la velocidad según el algoritmo original, o incorporando el peso de inercia o coeficiente de contracción. Se actualiza la posición de acuerdo a la velocidad obtenida para cada una de las partículas y se evalúa nuevamente el J . Si se cumple la condición de término se aplica $u(t)$ y si no, se aumenta en 1 el contador de generaciones y se vuelve a actualizar velocidad y posición.

3.4. Discusión

Hasta este momento se ha presentado el problema de optimización que surge a partir de la estrategia de control FPC – T&S y las posibles soluciones que se plantean.

Como posibles soluciones se encuentran los algoritmos tradicionales basados en gradiente y los evolutivos que realizan una búsqueda estocástica en el espacio de soluciones factibles.

El problema que plantea la estrategia de control predictivo FPC - T&S es no lineal y multidimensional por lo que puede generar una gran cantidad de mínimos locales y se debe solucionar en cada instante de tiempo de simulación. Este tipo de problemas no es fácilmente manejable por los algoritmos tradicionales basados en gradiente que tienden a caer en estos mínimos locales y son dependientes de las condiciones iniciales. Esto provoca un bajo desempeño del controlador desde el punto de vista del control y mientras mayor sea la dimensionalidad mayor es el uso del tiempo computacional.

En este capítulo se presentan ejemplos de la literatura que muestran que los algoritmos de computación evolutiva han demostrado que pueden manejar con buenos resultados este tipo de complejidades, tanto desde el punto de vista del control como del tiempo computacional.

La utilización de los algoritmos de computación evolutiva serán utilizados en los siguientes capítulos para comprobar estos mejores resultados esperados.

4. FPC basado en Algoritmos Evolutivos Aplicados a Series benchmark

4.1. Introducción

Para analizar las bondades de la estrategia de control se utilizarán tres series no lineales propuestas por Narendra (1990) y luego documentadas en la literatura para hacer benchmarks con diferentes estrategias de control (Shin and Park, 1998; Wang and Langary, 1995; Sáez *et al.*, 2002; Solís *et al.*, 2006; Zhixiang *et al.*, 2008).

Las funciones son las siguientes:

$$y(k+1) = \frac{y(k)y(k-1)[y(k)+2.5]}{1+y^2(k)+y^2(k-1)} + u(k) \quad (29)$$

$$y(k+1) = \frac{y(k)}{1+y^2(k)} + u^3(k) \quad (30)$$

$$y(k+1) = \frac{5y(k)y(k-1)}{1+y^2(k)+y^2(k-1)+y^2(k-2)} + u(k) + 0.8u(k-1) \quad (31)$$

Estas series fueron implementadas en MATLAB SIMULINK y fueron identificadas con modelos ARIX y difusos T&S, los modelos se encuentran en el ANEXO.

4.1.1. Serie 1

4.1.1.1. Resultados de Control

A continuación se presenta la aplicación de la estrategia FPC basada en algoritmos evolucionarios (Solís *et al.*, 2006).

Los parámetros para cada uno de los algoritmos son los siguientes:

- FPC-PSO:
 - Peso de inercia inicial 0.95
 - Peso de inercia final 0.3
 - El decrecimiento del peso de inercia es en el 70% de las iteraciones.
 - $V_{max} = X_{max}$.
- FPC-SGA:
 - crossover 100%
 - mutación 7%.
 - Ranking, SUS y re inserción basada en el fitness.
- FPC – NGA:
 - Solo Crossover sin mutación.

El número de individuos o partículas para los tres algoritmos y la precisión de bits para los GAs se presentan en la **Tabla 1**.

Tabla 1. Casos para el número de partículas (part.) o individuos (ind.) y precisión de bits (prec.)

	FPC - PSO			FPC - NGA			FPC - SGA		
	Part	Gen.	Ind.	Gen.	Prec.	Ind.	Gen.	Prec.	
1	100	100	100	100	10	100	100	10	
2	100	200	100	200	10	100	200	10	
3	200	100	200	100	10	200	100	10	
4	200	200	200	200	10	200	200	10	
5			100	100	20	100	100	20	
6			100	200	20	100	200	20	
7			200	100	20	200	100	20	
8			200	200	20	200	200	20	

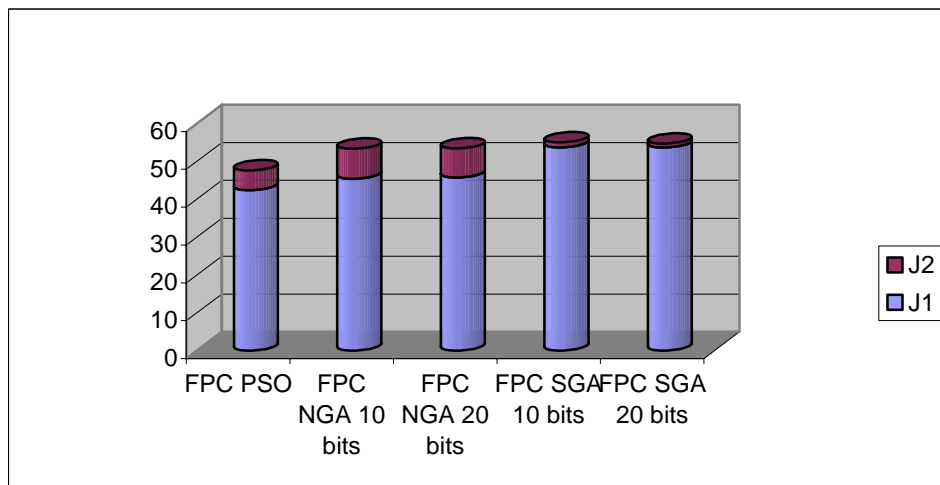


Figura 9 Valores medios de la función objetivo (J, J1, J2) para las distintas estrategias de FPC basado en algoritmos evolucionarios.

El comportamiento de los algoritmos será comparado utilizando dos indicadores principales. El primero es la función objetivo presentada en la **Ecuación (1)**, en la que se incorporan el seguimiento de la referencia y el esfuerzo de control. Como segunda medida de comparación se utiliza el tiempo computacional, que indica la factibilidad de que el algoritmo entregue una solución al problema de optimización en tiempo real.

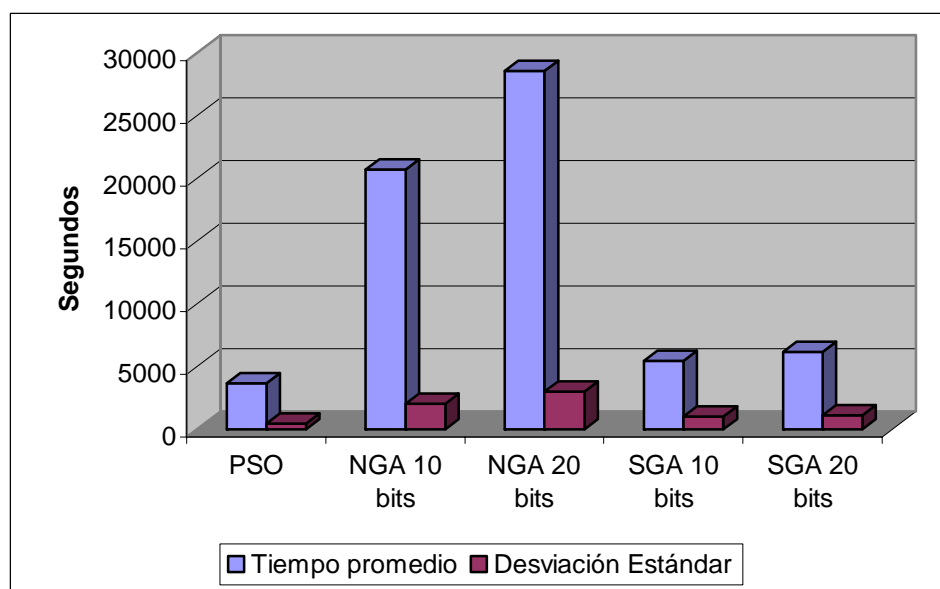


Figura 10 Valores medios y desviación estándar del tiempo computacional para las distintas estrategias de FPC basado en algoritmos evolucionarios.

El valor medio de la función objetivo para las diferentes estrategias se presenta en la **Figura 9** y los tiempos computacionales en la **Figura 10**.

En la primera figura se ilustra que el comportamiento del valor J es menor para la estrategia de control FPC –PSO en comparación con las diferentes estrategias basadas en SGA y NGA. Este comportamiento indica que la estrategia basada en PSO presenta un desempeño superior en la búsqueda del mínimo de la función objetivo. Si se analiza por separado el comportamiento de J_1 y J_2 , se observa que PSO presenta un mayor esfuerzo de control, J_2 , en comparación con GA. En cambio, se observa un mayor esfuerzo de control con NGA. Si se analiza el comportamiento de J_1 se ve que PSO tiene un mejor desempeño que NGA y SGA respectivamente.

En la **Figura 10** se observa el desempeño relacionado con el tiempo computacional de las estrategias propuestas en el que PSO entrega mejores resultados en comparación con SGA y NGA. El tiempo promedio que necesita PSO para resolver el problema de optimización es menor en comparación tanto con SGA como con NGA. Asimismo, se ve que este comportamiento es consistente ya que la desviación estándar es menor para la estrategia PSO.




Figura 11 Comportamiento de las estrategias FPC basado en algoritmos evolucionarios.

En las **Figuras 11 y 12**, se ilustra el comportamiento de la señal controlada ante cambios de tipo escalón en las diferentes estrategias propuestas. En la primera figura se puede observar como las tres estrategias propuestas realizan el seguimiento al set point. La que presenta un mejor desempeño ante los cambios en esta referencia es FPC-PSO ya que su respuesta es suave y rápida. Además, de acuerdo a lo ilustrado en la **Figura 9** se concluye que este comportamiento minimiza la función objetivo, es decir, a pesar que se observa un sobrepaso mayor que SGA, el esfuerzo de control para lograr ese comportamiento suave, sin ruido, es menor que en los otros casos. La segunda figura muestra el comportamiento de la señal ampliado para ver las componentes de ruido que generan los algoritmos.




Figura 12 Acercamiento del comportamiento de las estrategias FPC basado en algoritmos evolucionarios.

En estos resultados se puede observar que el comportamiento de FPC - PSO es más suave y converge más rápidamente a la referencia, lo que favorece la minimización de la función objetivo. FPC-SGA presenta una convergencia más lenta que FPC-NGA, presentando este último una mayor energía de control.

En este primer análisis del comportamiento de la Serie 1, sólo se utilizan algoritmos de computación evolutiva con el fin de compararlos. Además, como estrategia de inicialización de las poblaciones o enjambres, se genera una nueva en cada instante de simulación para comenzar con la optimización.

4.1.2. Serie 2

Esta serie se utilizó en Narendra y Parasarathi, (1990), para un trabajo de identificación y control basados en redes neuronales. Se aplicará el mismo procedimiento que con la serie de Chen.

Se ha escogido para el proceso de identificación una señal que excitará la planta mediante un ruido blanco discreto en un rango $[-2, 2]$ para obtener datos en la salida entre $[-8, 8]$.

$$y(k+1) = \frac{y(k)}{1+y(k)^2} + u(k)^3 \quad (32)$$

4.1.2.1. Resultados de Control

En esta serie se realizaron una cantidad mayor de pruebas para poder realizar una sensibilización de parámetros con respecto a la estrategia de computación evolutiva que ha resultado más atractiva, es decir, PSO.

Se realizaron variaciones en la estrategia FPC-PSO:

Tabla 2. Casos para el algoritmo FPC - PSO

Parámetro	Valor
<i>Peso de inercia inicial</i>	0.90, 0.95, 0.99.
<i>Peso de inercia final</i>	0.3
<i>El decrecimiento del peso de inercia</i>	70% de las iteraciones.
<i>Vmax = Xmax.</i>	0.02; 0.03; 0.04; 0.05; 0.06; 0.07; 0.08; 0.09.
<i>Partículas</i>	5, 10, 20, 30, 40, 50, 80, 100 y 200.
<i>Generaciones</i>	10, 20, 30, 40, 50, 60, 100, 200, 400
<i>χ</i>	0.73; 1

Con esta serie se realizaron una gran cantidad de pruebas que entregan información importante para ver el comportamiento de los algoritmos en función de sus principales parámetros.

En la **Figura 13**, se presenta el comportamiento del algoritmo FPC-PSO en función de las generaciones y las partículas. El efecto de las generaciones en la función objetivo es que a medida que éstas aumentan en el proceso de optimización los resultados son menos sensibles al efecto del número de partículas. Con esto se puede determinar un número de generaciones en el que la influencia del número de partículas no es significativa. El efecto del número de partículas muestra que a mayor número de partículas los resultados son más consistentes, presentándose iguales o mejores resultados que los algoritmos tradicionales tipo FPC - LM consistentemente. En cambio para un menor número de partículas se observa que el comportamiento es más disperso.




Figura 13. Comportamiento de FPC-PSO en función de generaciones y partículas.

En la **Figura 14**, se muestra el efecto de J en presencia del factor de constricción. En este se muestra que al aplicar un χ de 0.73 se obtiene un menor valor para J. El tiempo computacional para ambas estrategias es similar no presentándose variaciones significativas.

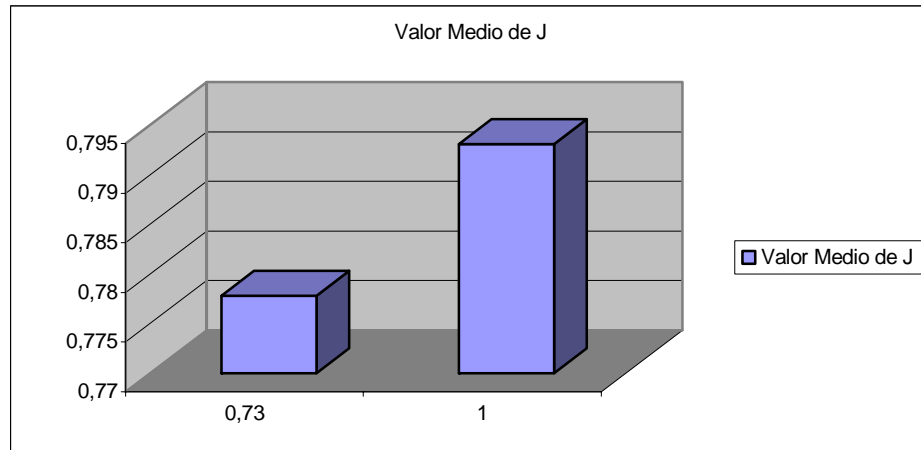


Figura 14. Comportamiento en función del Factor de Constricción.

En la **Figura 15**, se realiza un análisis similar para el peso de inercia, ω , en el que la estrategia de implementación es diferente. En ésta se utiliza un peso de inercia decreciente en el tiempo³. En el eje x se presenta el peso de inercia inicial que se elige de acuerdo a la necesidad de realizar exploración o explotación del espacio de soluciones factibles. De las 3 estrategias presentadas, 0.99, 0.91 y 0.90, el valor que permite mayor “exploración” (0.99) es el que entrega mejores resultados. El comportamiento de J es mejor si se permite “exploración” y decrece de acuerdo a la disminución del peso de inercia inicial.

³ Para ver más detalles de la implementación de los pesos de inercia decrecientes, ver el Capítulo 3.

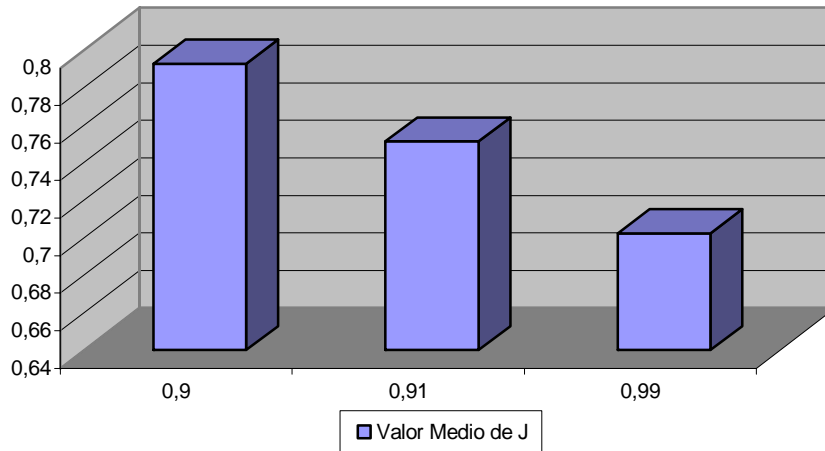


Figura 15. Comportamiento en función del peso de inercia.

En estas últimas figuras se encuentran los resultados más relevantes de este análisis, en los que se aprecia que para 40 partículas los resultados de FPC – PSO son consistentemente superiores a FPC- LM (**Figura 13**). En los resultados medios para χ la mejor estrategia es 0.73 con lo que se valida la teoría presentada en el Capítulo 3 (**Figura 14**). En el caso del peso de inercia inicial, se determina que al comienzo de la optimización se debe tener decididamente una estrategia de exploración (**Figura 15**).

Esta **Serie N°2** tiene un comportamiento no lineal más marcado que la **Serie N°1**. A pesar de esta mayor no linealidad, el problema de optimización sigue siendo manejable por estrategias tradicionales de tipo FPC – LM, que son competitivas con las estrategias propuestas. Esto se cumple en general para SGA y NGA, en cambio FPC-PSO con una cantidad de partículas, que depende del problema propuesto, puede superar consistentemente a la estrategia convencional.

4.1.3. Serie 3

4.1.3.1. Resultados de Control

La planta es de la siguiente forma:

$$y(k+1) = \frac{5y(k)y(k-1)}{1+y^2(k)+y^2(k-1)+y^2(k-2)} + u(k) + 0.8u(k-1)$$

Esta planta presenta una mayor complejidad en comparación con la **Serie N°1**. Los resultados por simulación son similares igualmente en el comportamiento. Se corrieron los mismos casos que para la **Serie N°1 (Tabla 3)**.

Esta **Serie N°3**, se utilizó para comparar las estrategias convencionales y las propuestas. FPC – LM logra el mejor desempeño tanto en la minimización de J como en los tiempos computacionales. FPC-PSO presenta el mejor comportamiento entre las estrategias de control evolutivas.

Tabla 3. Casos para el número de partículas (part.) o individuos (ind.) y precisión de bits (prec.)

	FPC - PSO		FPC - NGA		FPC - SGA			
	Part	Gen.	Ind.	Gen.	Prec.	Ind.	Gen.	Prec.
1	100	100	100	100	10	100	100	10
2	100	200	100	200	10	100	200	10
3	200	100	200	100	10	200	100	10
4	200	200	200	200	10	200	200	10
5			100	100	20	100	100	20
6			100	200	20	100	200	20
7			200	100	20	200	100	20
8			200	200	20	200	200	20

Con esta serie se introduce un cambio en la estrategia de inicialización de la población en cada instante de simulación. Esta modificación consiste en mantener un registro de la última población del algoritmo en cada instante de simulación. Luego esta población es la inicial en el siguiente instante de simulación, es decir, en cada instante de simulación del problema de control

se aplica el algoritmo propuesto, entregando un resultado que es aplicado al proceso, el que es utilizado para determinar que todos los individuos o partículas de esa última generación son guardados en una variable auxiliar que es utilizada para el siguiente instante de simulación. Esta modificación se presenta en la **Figura 16**.

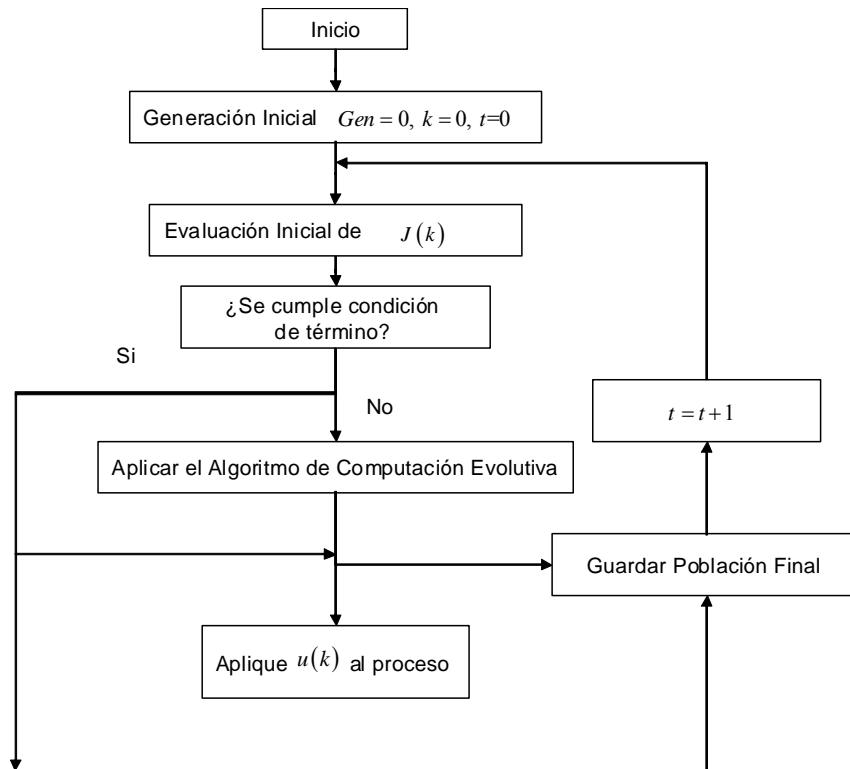


Figura 16. Modificación a la Aplicación de los Algoritmos

La aplicación de esta estrategia permitió que se disminuyera el ruido producido por el algoritmo de optimización, que se aprecia más en el caso de NGA y SGA (**Figura 12**). La **Figura 17** presenta un resumen de los resultados obtenidos en las simulaciones. El algoritmo FPC – LM presenta el mejor desempeño. Entre los algoritmos evolutivos el que se comporta de mejor manera es FPC – PSO.

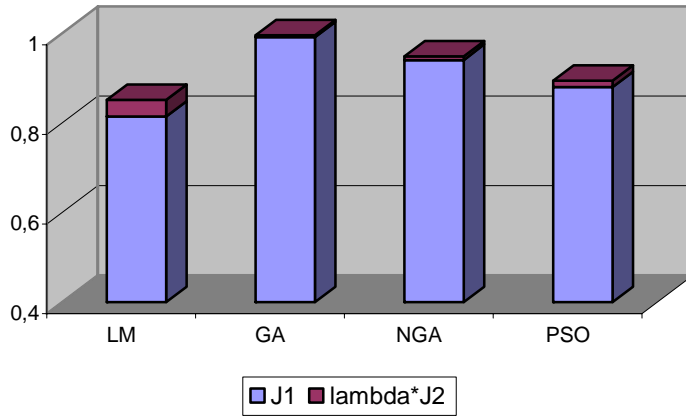


Figura 17. Valores medios de la función objetivo (J, J1, J2) en función de los algoritmos de optimización.

La estrategia de inicialización propuesta resultó ser un aporte ya que permite utilizar el conocimiento de la población en conjunto, no sólo de los mejores individuos o de la solución anterior, sino que aprovecha la riqueza genética de todos los individuos de la población que contiene al mejor individuo. Con esto se logró disminuir la variabilidad que se provoca al generar una nueva población en cada instante de simulación.

4.2. **Discusión**

La utilización de las nuevas estrategias de optimización aplicadas a problemas de control predictivo se ha mostrado como una eficaz herramienta que permite mejorar significativamente el desempeño tanto en el costo como en el tiempo computacional.

En la Serie 1 se comprobó por medio de simulaciones que la estrategia propuesta cumple con el objetivo de realizar el seguimiento de la variable controlada con el menor esfuerzo computacional, presentando un mejor resultado la estrategia basada en PSO en comparación con las basadas en GAs. Esto principalmente por lo robusto de los resultados y el menor tiempo computacional utilizado.

Una vez analizado el comportamiento de los problemas de optimización de control predictivo por medio de los algoritmos propuestos, se realizó una prueba por simulación en la Serie 2 para comparar el desempeño de las variaciones al algoritmo PSO original. Se pudo comprobar que en general se presenta un comportamiento robusto para cada una de las combinaciones de parámetros elegida. En particular se encontró que la utilización de por lo menos 30 partículas en 50 iteraciones es la mejor combinación de parámetros para PSO, tanto si se utiliza peso de inercia decreciente como Factor de Contricción. Para el peso de inercia se comprobó que la utilización del valor calculado por Clerc, (1999), es el que obtiene un mejor comportamiento. En el caso del peso de inercia decreciente se obtiene como resultado que se debe utilizar en el inicio un valor alto que permita explorar en una amplia zona de la región de soluciones factibles.

En la Serie 3, se introduce una modificación en la implementación del algoritmo. La idea es que una vez alcanzada la referencia no es necesario realizar una inicialización desde cero a la población de partículas, sino que se guarda la riqueza genética obtenida en el instante de

muestreo anterior para que la optimización converja de mejor manera al óptimo y no pierda tiempo o calidad por mantener la aleatoriedad de elección de las poblaciones iniciales. Se debe recordar que en cada instante de simulación se debe aplicar el algoritmo elegido para que se converja a la solución deseada para ese momento de simulación, por lo que las estrategias han apuntado a que se llegue a la referencia con el mejor desempeño posible.

En conclusión se pudo apreciar un buen comportamiento por parte de las estrategias propuestas encontrándose un mejor desempeño en la utilización del algoritmo PSO con 30 partículas y 50 iteraciones utilizando la población inmediatamente anterior al instante de muestreo. Esta estrategia se comprobará en el siguiente capítulo a una planta termoeléctrica de ciclo combinado por simulación.

5. Aplicación al Control de una Caldera Recuperadora de Calor de una Central Termoeléctrica de Ciclo Combinado

5.1. Introducción

En este capítulo se presenta la aplicación principal de esta tesis y su principal aporte. Esta aplicación es una Caldera Recuperadora de Calor de una Planta Termoeléctrica de Ciclo Combinado⁴ mediante el simulador propuesto por Ordys *et al.* (1994) e implementado por Sáez *et al.*(2000).

Los algoritmos propuestos fueron implementados para realizar un control supervisor predictivo y los resultados son presentados a continuación.

⁴ Una revisión de la teoría de Calderas de Plantas Termoeléctricas de Ciclo Combinado se presenta en el Anexo II.

5.2. Planteamiento del Problema de Control

Supervisor

La estrategia de control supervisor se diseña con el objetivo de determinar las referencias óptimas para el nivel regulatorio. La inclusión de un criterio económico es una de las principales diferencias con las estrategias de control a nivel regulatorio. La aplicación del nivel supervisor considera que se mantienen los lazos PID aplicados al sistema.

5.2.1. Función Objetivo

En esta aplicación, el nivel supervisor consiste en un optimizador predictivo que considera como restricciones no lineales del problema las predicciones de la planta y la modelación discreta del nivel regulatorio. Las variables involucradas en el modelo de la caldera son la presión de vapor sobrecalentado, p_s , y el nivel de agua L en el domo que están relacionadas con los flujos de combustible (w_F) y flujo de agua de alimentación (w_e). La **Figura 18** muestra la configuración del controlador a utilizar.

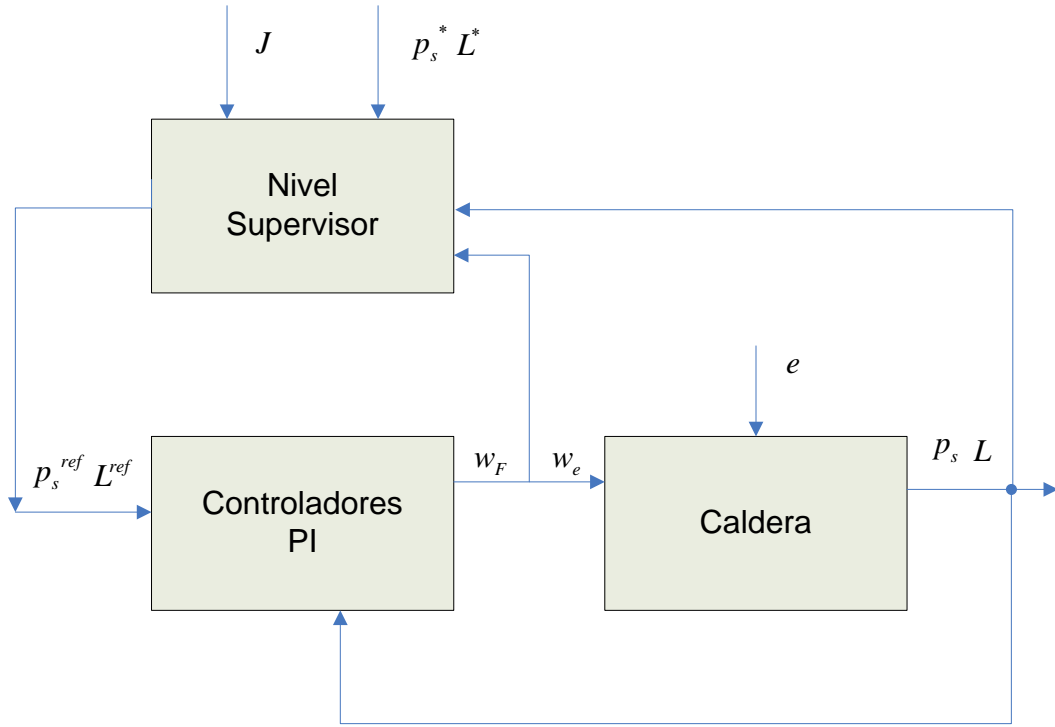


Figura 18. Control Predictivo a Nivel Supervisor

La función objetivo considerada incluye el nivel regulatorio y el económico. En la **Ecuación (34) y (35)** se aprecian ambos términos, J_{C_f} que considera el objetivo económico relativo a los costos de operación de la planta, que deben ser minimizados; J_{C_r} , es el término comúnmente utilizado en MPC, que suma el efecto del seguimiento de la referencia y el esfuerzo de control, añadiendo un ponderador η de los efectos de ambos.

$$J = J_{C_f} + \eta \cdot J_{C_r} \quad (33)$$

Cada término se descompone según las **Ecuaciones (34) y (35)**.

$$J_{C_f} = \sum_{i=1}^N C_f w_f(t+i-1) + \sum_{i=1}^N C_e w_e(t+i-1) + CF \quad (34)$$

$$J_{C_r} = C_{r_{ps}} \left[\sum_{j=1}^N (\hat{p}_s(t+j) - p_s^*)^2 + \lambda_{w_f} \sum_{i=1}^N \Delta w_f^2(t+i-1) \right] + \\ + C_{r_L} \left[\sum_{j=1}^N (\hat{L}(t+j) - L^*)^2 + \lambda_{w_e} \sum_{i=1}^N \Delta w_e^2(t+i-1) \right] \quad (35)$$

En el que C_f es el costo de combustible, C_e el costo de suministro del agua de alimentación y CF son los costos fijos de operación, tales como el costo de la dotación, administración y servicios. Las variables controladas son las siguientes: presión del vapor sobrecalentado (p_s) y nivel del tambor (L) y las variables manipuladas son el flujo de combustible (w_f) y el flujo de agua de alimentación (w_e). El horizonte de predicción y control es N . $\hat{p}_s(t+j)$ es la j -ésima predicción de la presión de vapor sobrecalentado y $\hat{L}(t+j)$ es la j -ésima predicción para el nivel del domo. $C_{r_{ps}}$ y C_{r_L} son los factores de costo para el nivel regulatorio y λ_{w_f} y λ_{w_e} son los pesos del esfuerzo de control. p_s^* y L^* son los setpoints para la presión de vapor sobrecalentado y el nivel.

5.2.2. Restricciones

Tal como se mencionó previamente este tipo de estrategias permite incorporar restricciones a las variables que aseguren un comportamiento seguro, tales como:

- Niveles mínimos para el nivel en el domo.

$$\triangleright L(t) \geq L_{\min} \quad (36)$$

- Niveles mínimos para el flujo de vapor y el de combustible debido a limitaciones operacionales que impone la planta.

$$\triangleright w_e(t) \geq w_{e\min} \quad (37)$$

$$\triangleright w_f(t) \geq w_{f\min} \quad (38)$$

- Límites máximos de flujo de vapor y combustible impuestos por el pipeline.

$$\triangleright w_e(t) \leq w_{e\max} \quad (39)$$

$$\triangleright w_f(t) \leq w_{f\max} \quad (40)$$

5.2.3. Parámetros

A continuación se incluyen los parámetros extraídos de Sáez *et al.* (2002)

Tabla 4. Parámetros de la Función Objetivo y Restricciones.

Parámetros	Valores	Unidades
C_f	100	[\$/kg]
C_e	1	[\$/kg]
P_s^*	4.5251×10^6	[psi]
L^*	4.1425	[m]
$C_{r_{ps}}$	10^{-9}	-
C_{r_L}	10^6	-
λ_{w_F}	10^{11}	-
λ_{w_e}	1	-
L_{\min}	4.138	[m]
w_{\min}	10	[kg/seg]
$w_{F \min}$	13	[kg/seg]
w_{\max}	14	[kg/seg]
$w_{F \max}$	16	[kg/seg]

5.3. Control Supervisor basado en Modelos

Difusos de la Caldera

En este caso, las variables controladas son la presión del vapor sobrecalentado (p_s) y nivel del tambor (L) y las variables manipuladas son el flujo de combustible (w_f) y el flujo de agua de alimentación (w_e).

En esta tesis se analiza el comportamiento ante cambios de referencia de algunas variables de relevancia para poder realizar la identificación de ésta.

Los cambios de referencia se han planteado en las siguientes variables: en el nivel y en la temperatura de vapor sobrecalentado.

Como se mencionó anteriormente la idea es poder entender el comportamiento de la planta en lazo cerrado para poder realizar la identificación de la planta utilizando el toolbox de identificación difusa T&S.

En esta tesis se utiliza un esquema simplificado de la caldera de la central termoeléctrica de ciclo combinado, extraído de (Sáez *et al.*, 2002).

Las reglas del modelo difuso son las siguientes:

$$R_1 : \text{Si } ps(t-1) \text{ es } A_1^1 \text{ y } ps(t-2) \text{ es } A_1^2 \text{ y } w_f(t-1) \text{ es } A_1^3 \text{ y } w_f(t-2) \text{ es } A_1^4 \text{ y } w_e(t-1) \text{ es } A_1^5 \text{ y } w_e(t-2) \text{ es } A_1^5 \\ \text{entonces } ps_1(t) = g_0^1 + g_1^1 ps(t-1) + g_2^1 ps(t-2) + g_3^1 w_e(t-1) + g_4^1 w_e(t-2) + g_5^1 w_f(t-1) + g_6^1 w_f(t-2) \quad (41)$$

$$R_2 : \text{Si } ps(t-1) \text{ es } A_2^1 \text{ y } ps(t-2) \text{ es } A_2^2 \text{ y } w_f(t-1) \text{ es } A_2^3 \text{ y } w_f(t-2) \text{ es } A_2^4 \text{ y } w_e(t-1) \text{ es } A_2^5 \text{ y } w_e(t-2) \text{ es } A_2^5 \\ \text{entonces } ps_2(t) = g_0^2 + g_1^2 ps(t-1) + g_2^2 ps(t-2) + g_3^2 w_e(t-1) + g_4^2 w_e(t-2) + g_5^2 w_f(t-1) + g_6^2 w_f(t-2)$$

$$R_1 : \text{Si } L(t-1) \text{ es } A_1^1 \text{ y } L(t-2) \text{ es } A_1^2 \text{ y } w_F(t-1) \text{ es } A_1^3 \text{ y } w_F(t-2) \text{ es } A_1^4 \text{ y } w_e(t-1) \text{ es } A_1^5 \text{ y } w_e(t-2) \text{ es } A_1^5 \\ \text{entonces } L_1(t) = g_0^1 + g_1^1 L(t-1) + g_2^1 L(t-2) + g_3^1 w_e(t-1) + g_4^1 w_e(t-2) + g_5^1 w_F(t-1) + g_6^1 w_F(t-2) \quad (42)$$

$$R_2 : \text{Si } L(t-1) \text{ es } A_2^1 \text{ y } L(t-2) \text{ es } A_2^2 \text{ y } w_F(t-1) \text{ es } A_2^3 \text{ y } w_F(t-2) \text{ es } A_2^4 \text{ y } w_e(t-1) \text{ es } A_2^5 \text{ y } w_e(t-2) \text{ es } A_2^5 \\ \text{entonces } L_2(t) = g_0^2 + g_1^2 L(t-1) + g_2^2 L(t-2) + g_3^2 w_e(t-1) + g_4^2 w_e(t-2) + g_5^2 w_F(t-1) + g_6^2 w_F(t-2)$$

Los parámetros de los conjuntos difusos y las consecuencias están en las **Tablas 5 y 6**.

Tabla 5. Parámetros del Modelo Difuso. Presión de Vapor Sobrecalentado

Regla i	a_1^i	a_2^i	a_3^i	a_4^i	a_5^i	a_6^i
1	$5,96 \cdot 10^{-5}$	$5,96 \cdot 10^{-5}$	1,9013	1,9011	1,7208	1,7207
2	$3,67 \cdot 10^{-5}$	$5,69 \cdot 10^{-5}$	1,3568	1,3569	1,8133	1,6869

Regla i	b_1^i	b_2^i	b_3^i	b_4^i	b_5^i	b_6^i
1	$4,53 \cdot 10^6$	$4,53 \cdot 10^6$	14,038	14,038	11,99	11,99
2	$4,54 \cdot 10^6$	$4,53 \cdot 10^6$	14,137	14,138	11,871	11,799

Regla i	g_0^i	g_1^i	g_2^i	g_3^i	g_4^i	g_5^i	g_6^i
1	$4,43 \cdot 10^5$	1,5538	-0,6481	15454	-14937	-3338,5	1393
2	$2,88 \cdot 10^5$	1,6488	-0,71003	14902	-14334	-3599,6	2033,3

Tabla 6. Parámetros del Modelo Difuso. Nivel.

Regla i	a_1^i	a_2^i	a_3^i	a_4^i	a_5^i	a_6^i
1	9,2078	9,2158	1,9024	1,9023	1,721	1,721
2	10,937	10,905	1,7797	1,7813	2,0005	1,8913

Regla i	b_1^i	b_2^i	b_3^i	b_4^i	b_5^i	b_6^i
1	4,0599	4,06	14,038	14,038	11,99	11,99
2	4,0621	4,0636	14,302	14,303	11,806	11,8

Regla i	g_0^i	g_1^i	g_2^i	g_3^i	g_4^i	g_5^i	g_6^i
1	-0,090749	1,3648	-0,36505	0,00060389	-0,00026747	0,010108	-0,0028556
2	-0,078429	1,4836	-0,48338	0,0006797	-0,00028471	0,010185	-0,004188

A continuación se presentan los resultados a 10 pasos con modelos lineales y difusos para el nivel L y la presión de vapor sobrecalentado ps.




Figura 19 Identificación mediante modelo difuso T&S. Error Cuadrático Medio (MSE) a 10 pasos = 0.0062241.

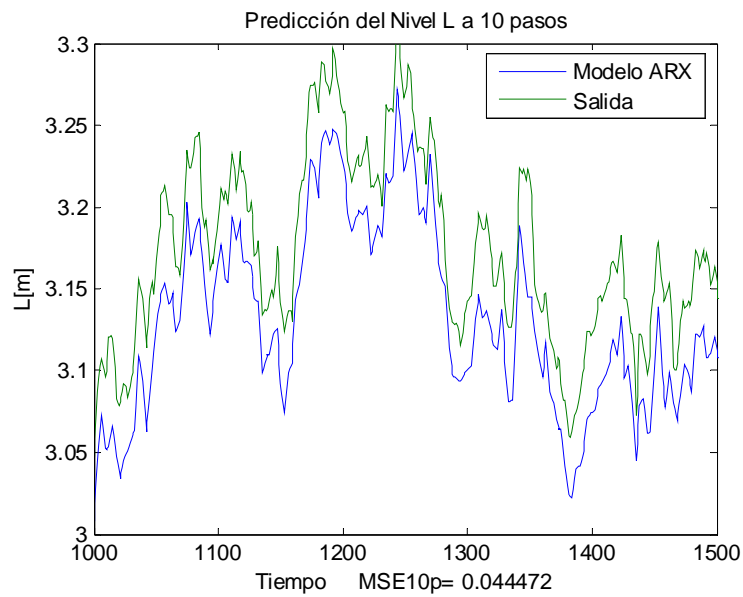


Figura 20. Identificación mediante modelo lineal ARX. MSE a 10 pasos = 0.0044472.

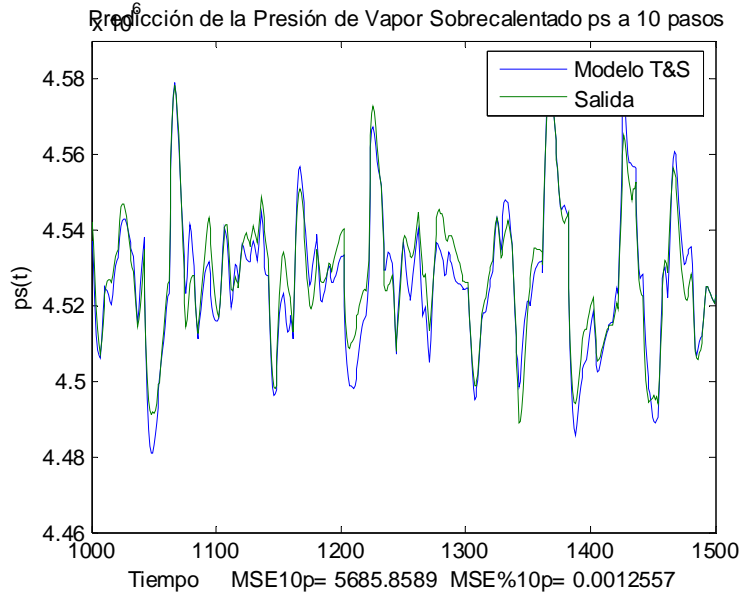


Figura 21. Identificación mediante modelo difuso T&S. MSE a 10 pasos = 5685.8589




Figura 22. Identificación mediante modelo lineal ARX. MSE a 10 pasos = 17582.4186

Los resultados de identificación se miden de acuerdo a la medida del Error Cuadrático Medio (MSE, Mean Square Error). El modelo será mejor si es que su MSE es menor. En el caso de realizar una identificación para aplicar control predictivo se utiliza una medida de error que permita analizar las bondades del modelo en el horizonte de predicción. En el caso de la presente tesis el horizonte de predicción es de 10 por lo que la medida de error que se analizará principalmente es MSE a 10 pasos.

En las **Figuras 19 a 22** se presentan los resultados de identificación tanto para L como para ps. Se observa que a 10 pasos los modelos difusos presentan un mejor desempeño en la etapa de identificación.

En las **Tablas 7 y 8** se presenta un resumen de los resultados obtenidos en la etapa de identificación, en los que se observa que los modelos difusos entregan una mejor representación del comportamiento de ambas señales en el horizonte de predicción.

Tabla 7. Error a 1 y 10 pasos para modelo lineal ARX y difuso T&S. Nivel.

	Modelo Difuso T&S	Modelo Lineal ARX	Mejora Porcentual
Error a 1 Paso	0,00046102	0,00092699	201%
Error a 10 Pasos	0,0064119	0,044472	694%

En caso del nivel, se observa que los modelos lineales presentan un MSE a 1 paso que dobla a los modelos difusos. Esta diferencia se amplifica por tres veces en el caso del MSE a 10 pasos. Esto muestra que las funciones difusas representan mejor las no linealidades que posee el comportamiento de la planta de ciclo combinado.

Tabla 8. Error a 1 y 10 pasos para modelo lineal ARX y difuso T&S. presión de vapor sobrecalentado

	Modelo Difuso T&S	Modelo Lineal ARX	Mejora Porcentual
Error a 1 Paso	1059,4656	1360,2891	128%
Error a 10 Pasos	5746,1549	17586,2404	306%

En el caso de la presión de vapor sobrecalentado el comportamiento a 1 paso es relativamente superior, mostrándose un aumento de tres veces del MSE a 10 pasos, aumento similar al caso del nivel.

Como resultado de este análisis se puede inferir que la aplicación de una estrategia FPC, es decir, que utiliza modelos de tipo difuso para predecir el comportamiento en el futuro de la planta, será superior un MPC que utilice modelos lineales para la etapa de identificación.

5.3.1. Modelo del Controlador PI

La modelación se realiza de acuerdo a la discretización del Controlador PI para la presión de vapor sobrecalentado (**Ecuación (43)**).

$$A_c(z^{-1})w_F(t) = B_{cr}(z^{-1})p_s^*(t) + B_{cy}(z^{-1})p_s(t) \quad (43)$$

Con

$$A_c(z^{-1}) = 1 - z^{-1}$$

$$B_{cr}(z^{-1}) = 1.5005 \cdot 10^{-5} - 1.4995 \cdot 10^{-5} z^{-1}$$

$$B_{cy}(z^{-1}) = -1.5005 \times 10^{-5} + 1.4995 \times 10^{-5} z^{-1}$$

$$K_p = 1.5 \cdot 10^{-5}, K_i = 1 \cdot 10^{-9}$$

La discretización para el caso del nivel se representa en la **Ecuación (44)**.

$$A_c(z^{-1})w_e(t) = B_{cr}(z^{-1})L^*(t) + B_{cy}(z^{-1})L(t) \quad (44)$$

Con

$$A_c(z^{-1}) = 1 - z^{-1}$$

$$B_{cr}(z^{-1}) = 258 - 86.15z^{-1}$$

$$B_{cy}(z^{-1}) = -258 + 86.15z^{-1}$$

$$K_p = 10, K_i = 1$$

La válvula de alimentación de agua se modela como sigue, x_1 es la posición de la válvula:

$$w_e = f(x_1) = 17.23 x_1 \quad (45)$$

Tal como se muestra en el principio del capítulo para la implementación del Control Supervisor Predictivo se necesitan los modelos de las variables a controlar y la representación del controlador PI para cada variable.

Las pruebas de los controladores se realizarán soportando los cambios en el flujo de vapor sobrecalentado w_s , que corresponde a los cambios en la potencia producida por la turbina a vapor de la central termoeléctrica. La influencia de esta variable para efectos del control se considera como una perturbación. En la **Figura 23** se muestra esta perturbación.

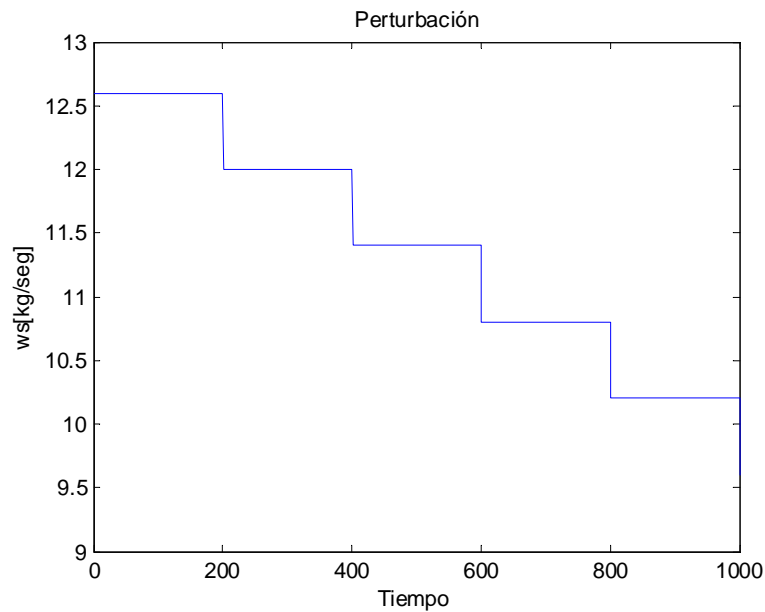


Figura 23. Cambio en Flujo de Vapor Sobrecalentado (w_s).

La comparación de las estrategias propuestas se realiza en base a la definición que se encuentra en la **Ecuación 46**.

$$\text{Ahorros} = \left(100 \cdot \left(1 - \frac{J_{C_{f1}}}{J_{C_{f2}}} \right) \right) \% \quad (46)$$

5.3.2. Resultados de Control

Se implementaron los algoritmos propuestos basados en Computación Evolutiva aplicados al simulador de una caldera de una planta termoeléctrica de ciclo combinado. En particular para generar la primera población se plantean nuevos límites mínimos y máximos de L y p_s que estén cerca de la solución.

Los parámetros a utilizar en la estrategia basada en GA son los siguientes:

Tabla 9. Parámetros SGA

Número de Individuos	10, 20, 50
Número de Generaciones	50, 100
Reproducción	100%
Mutación	7%
Método de Selección	Ranking con SUS
Precisión	30 bits
$L_{\text{máx}}$	4.2 [m]
$L_{\text{mín}}$	4.1 [m]
$p_{s \text{ máx}}$	$4.6 \cdot 10^6$ [psi]
$p_{s \text{ mín}}$	$4.4 \cdot 10^6$ [psi]

Los parámetros utilizados en la estrategia PSO son los siguientes:

Tabla 10. Casos para FPC - PSO

Número de Partículas	10, 20,50
Número de Iteraciones	50, 100
Peso de inercia inicial	0.99
Peso de inercia Final	0.2
Tiempo de variación de Peso de inercia	80% de las iteraciones
Coefficiente de Contracción	0.73
Vmáx	30%

En el caso de la estrategia basada en PSO se normaliza entre 0 y 1 para realizar la implementación y $V_{máx}$ depende de $p_{s_{máx}}$ y $L_{máx}$, es decir, los valores máximos de las variables controladas. Una vez definidos los parámetros de los algoritmos de optimización se realizaron pruebas con el simulador. Los resultados se presentan a continuación. En la **Tabla 11** encontramos los valores obtenidos de la simulación para la función objetivo (**Ecuación (33)**) y sus dos componentes, J_{C_f} y J_{C_r} . En esta tabla se presenta una comparación entre los valores obtenidos con PSO y SGA con similares condiciones, es decir, 10 individuos en SGA y 10 partículas en PSO, analizados desde el punto de vista de las generaciones o iteraciones. En la columna “Ahorros (%)”, se entrega el valor de la comparación introducido en la **Ecuación (46)**. En los casos planteados para comparación, a saber, 50 y 100 iteraciones, FPC – PSO entrega mejores resultados que FPC –SGA con ahorros del orden de 1,5%, encontrándose que presenta mejores resultados (es menor) en todos los valores componentes de la función objetivo (J_{C_f} y J_{C_r}), encontrándose que J es cerca de 6 veces menor en ambos casos. Asimismo, se ve que ambos algoritmos mejoran con una mayor cantidad de generaciones o iteraciones.

Tabla 11. Valores Medios de la Función Objetivo a nivel Regulatorio y Económico en función de las generaciones o iteraciones

N° Gen. ó Iter.	Control Supervisor Difuso basado en GA (10 Individuos)			Control Supervisor Difuso basado en PSO (10 Partículas)			Ahorros (%)
	J_{C_f} \$	J_{C_r} \$	J \$	J_{C_f} \$	J_{C_r} \$	J \$	
50	$1.0436 \cdot 10^4$	$1.6042 \cdot 10^{12}$	$1.6042 \cdot 10^{12}$	$1.0318 \cdot 10^4$	$2.568 \cdot 10^{11}$	$2.568 \cdot 10^{11}$	1.13%
100	$1.042 \cdot 10^4$	$1.6711 \cdot 10^{12}$	$1.6711 \cdot 10^{12}$	$1.030 \cdot 10^4$	$3.234 \cdot 10^{11}$	$3.234 \cdot 10^{11}$	1.152%

En la **Tabla 12**, se presentan los resultados a partir de una variación en el término ponderador η . Se presentan dos casos, η igual a 0,5 y a 1, encontrándose un mejor desempeño en cuanto a ahorros del orden de 1,5% para 0,5 que para 1. Este resultado también influye en el valor de J que disminuye con el uso del valor η igual a 0,5, esto es lógico debido a que en la ecuación de J , el valor referido al función objetivo predictiva (J_{C_r}) está ponderada por el término η , y que en particular para este problema, el valor J_{C_r} es superior a J_{C_f} por lo que al disminuir a la mitad su influencia, el valor total disminuye.

Tabla 12. Valores Medios de la Función Objetivo a nivel Regulatorio y Económico en función de η .

η	Control Supervisor Difuso basado en GA (10 Individuos, 50 Generaciones)			Control Supervisor Difuso basado en PSO (10 Partículas, 50 Iteraciones)			Ahorros (%)
	J_{C_f} \$	J_{C_r} \$	J \$	J_{C_f} \$	J_{C_r} \$	J \$	
1	$1.0436 \cdot 10^4$	$1.6042 \cdot 10^{12}$	$1.6042 \cdot 10^{12}$	$1.0318 \cdot 10^4$	$2.568 \cdot 10^{11}$	$2.568 \cdot 10^{11}$	1.132%
0.5	$1.042 \cdot 10^4$	$1.7291 \cdot 10^{12}$	$8.6453 \cdot 10^{11}$	$1.028 \cdot 10^4$	$3.1563 \cdot 10^{11}$	$1.5781 \cdot 10^{11}$	1.34%

En la **Tabla 13**, encontramos los resultados de la variación del número de individuos o partículas. Se puede observar que los valores medios de la función objetivo presentan una mejora que va desde un 1,3% a 15% de mejora en relación a los costos económicos. Esta mejora va creciendo a medida que va creciendo la cantidad de individuos del algoritmo.

Tabla 13. Valores Medios de la Función Objetivo a nivel Regulatorio y Económico ($\eta = 0.5$) en función del número de individuos o partículas.

N° Individuos	Control Supervisor Difuso basado en GA (100 Generaciones)			Control Supervisor Difuso basado en PSO (100 Iteraciones)			Ahorros (%)
	J_{c_f} \$	J_{c_r} \$	J \$	J_{c_f} \$	J_{c_r} \$	J \$	
10	$1.0436 \cdot 10^4$	$1.6044 \cdot 10^{12}$	$8.022 \cdot 10^{11}$	$1.0318 \cdot 10^4$	$2.568 \cdot 10^{11}$	$1.284 \cdot 10^{11}$	1.131%
20	$1.0435 \cdot 10^4$	$1.608 \cdot 10^{12}$	$8.04 \cdot 10^{11}$	$0.8814 \cdot 10^4$	$1.200 \cdot 10^{13}$	$6 \cdot 10^{12}$	15.5%
50	$1.041 \cdot 10^4$	$1.613 \cdot 10^{12}$	$8.04 \cdot 10^{11}$	$0.8800 \cdot 10^4$	$1.435 \cdot 10^{13}$	$7.175 \cdot 10^{12}$	15.5%

Cabe destacar que la utilización de la estrategia tradicional FPC – LM no entregó resultados, ya que cuando se implementó en MATLAB, con pocas iteraciones el sistema no era capaz de manejarlo por lo que no fue posible entregar una comparación con este algoritmo.

Comparando los algoritmos se puede ver que FPC-PSO entrega los mejores resultados en todas las cantidades de población, encontrándose que en este problema de optimización complejo se presentan mejoras considerables al aumentar el número de individuos.

Las pruebas de la aplicación de los algoritmos FPC – SGA y FPC – PSO fueron desarrolladas MIMO, 2 variables manipuladas (w_e, w_f) y 2 controladas (p_s, L). El comportamiento de estas variables se presenta en las **Figuras 24 y 25**.

En la **Figura 24**, se ilustra como las variables con la estrategia PSO tienen un mejor comportamiento de las variables controladas y manipuladas. Las variables controladas con FPC – PSO presentan un mejor desempeño en control ya que se ve como el sobrepaso y tiempo de

estabilización de éstas variables es menor. En el caso de las variables manipuladas, se observa en el caso de w_e una mayor actividad de control que está influida por el ponderador de este término en la función de costos y en el caso de w_f una menor actividad de control lo que también debe estar influenciado por el término ponderador. Estos resultados se obtuvieron para el caso con 50 individuos o partículas.




Figura 24. Comparación de las Variables Manipuladas y Controladas ante la aplicación de FPC con algoritmos de computación evolutivo PSO — GA .

En la **Figura 25**, se presentan los resultados con 10 partículas o individuos. Las variables tienen un comportamiento similar en todas las variables en cuanto al set point que entrega el control predictivo supervisor, sin embargo, el desempeño de control es superior para las variables controladas, tanto el sobrepaso como el tiempo de estabilización. Se puede observar que los objetivos de control, seguimiento de referencia y minimizar el esfuerzo de control son alcanzados de mejor manera por FPC – PSO, puesto que alcanza la referencia en un tiempo razonable (en comparación con el tiempo de estabilización en lazo abierto) y con un esfuerzo de control menor a los otros algoritmos.




Figura 25. Representación Variables Manipuladas y Controladas PSO — GA .

En la **Figura 26** se presentan los resultados para L de la aplicación de FPC a nivel supervisor en una ventana de tiempo. Se ilustra el comportamiento de la referencia (r_L) obtenida con el controlador FPC – PSO, y las variables tanto manipulada (w_e) y como controlada (L). La referencia calculada por el novel supervisor tiene un comportamiento suave que se ve afectado por el efecto de la perturbación aplicada (**Figura 24**) en determinados instantes de tiempo lo que genera una mayor actividad de la variable manipulada para mantener la variable controlada en la referencia deseada.




Figura 26. Control basado en PSO. L .

En la **Figura 27** se presentan los resultados obtenidos para la presión de vapor sobrecalentado (p_s) en el que se muestra un comportamiento similar del controlador y las variables.

Es fundamental en este análisis comprobar el comportamiento de las variables calculadas en el nivel supervisor por FPC – PSO (r_L y r_p), ya que la actividad de éstas ilustra que, primero, el controlador está realizando su trabajo, es decir, está funcionando y realizando el control que se le está pidiendo y, segundo, al ver la evolución de la referencia calculada en el tiempo es posible determinar que el controlador responde a las perturbaciones de buena manera. En ambos casos, FPC – SGA y FPC – PSO evidenciaron estos comportamiento, sin embargo, el que realiza de mejor manera es este último.




Figura 27. Control basado en PSO. p_s .

6. Conclusiones

En la implementación de las estrategias propuestas se aprecia como el desempeño de PSO es superior a Algoritmos Genéticos, esta mejora es superior en todos los casos al 1% para cantidades del orden de 10 individuos y aumenta hasta 15% para cantidades superiores a 20 individuos.

Para PSO las mejoras en desempeño de control (función de costos y económica, sobrenivel, tiempo de estabilización, entre otras) se obtienen cuando se produce un aumento de partículas donde se entregan desempeños superiores en todas las cantidades de individuos / partículas y se aprecian mejoras de 15% sobre 20 individuos /partículas.

En el caso de los tiempos se observó una mejora del orden de 40% para todas las cantidades de individuos.

El control basado en PSO presenta un comportamiento robusto en cuanto al número de generaciones donde hay mínimas mejoras en el aumento que se experimentó.

Se puede concluir que las estrategias de control predictivo difuso basado en algoritmos de computación evolutiva presentan una buena solución al problema de control planteado, ya que entregan consistentemente una solución al problema de optimización en comparación con LM. El mejor desempeño lo presenta FPC – PSO.

La estrategia de control predictivo con función cuadrática y modelos difusos presenta un problema difícil de solucionar para los algoritmos convencionales en tiempos razonables, siendo una buena herramienta la aplicación de algoritmos no convencionales de computación evolutiva, tanto por tiempos de desempeño como por resultados por simulación.

Este tipo de algoritmos evolutivos entregan una solución que mejora el desempeño a medida que se van aumentando las generaciones o iteraciones de los algoritmos. El objetivo de la estrategia de control referido a entregar una solución en tiempo real se ve afectado en forma inversa por la cantidad de generaciones, ya que el tiempo de solución del problema predictivo aumenta. Es necesario realizar un trade off al momento de implementar este tipo de estrategias entre el tiempo versus el desempeño de control.

Ante el surgimiento de muchas estrategias algorítmicas basadas en computación evolutiva se pudo responder de acuerdo a las simulaciones en la Caldera y en las series Benchmark que se obtienen mejores resultados con PSO con sus diferentes parámetros (N° de individuos, Cantidad de Generaciones, etc.)

Uno de los principales resultados por simulación fue la mejora que se produce al utilizar en cada instante de simulación la población anterior, realizando el proceso de inicialización de las poblaciones sólo en el instante cero de simulación. En los siguientes instantes se utilizó enteramente la población anterior que incluye el mejor individuo, sin embargo, al replicar solo el mejor individuo se produce una pérdida de riqueza genética que entregan las otras partículas/individuos, por lo que se decidió en este trabajo utilizar enteramente la población anterior como inicial. Los problemas de control alcanzan un régimen permanente luego de pasar el régimen de transientes, por lo que el razonamiento anterior parte de esa premisa, que en un punto de la simulación, la señal controlada alcanza el régimen permanente y el resultado del instante anterior es el óptimo, que puede ser mejorado en parte si es que se encuentra otra solución óptima. En el régimen transiente o en presencia de perturbaciones no medidas, es necesario realizar una mayor exploración del espacio de soluciones factibles y no solo la explotación del mejor individuo. Por lo tanto, la estrategia de inicialización planteada cumple con los requisitos necesarios para un problema de control.

Además, otra de las ventajas de utilizar esta estrategia es que se acelera el tiempo de optimización, ya que una de las etapas que se evita es la inicialización en cada instante de muestreo con el consiguiente ahorro de tiempo y recursos computacionales. En particular, las aplicaciones industriales en su mayoría no están utilizando algoritmos que optimizan en tiempo real, sino que utilizan una ley de control con parámetros variables. Esto último debido a la complicación que representa la utilización de recursos computacionales, para estar resolviendo el problema de control en cada instante de tiempo con algoritmos de optimización convencionales. Sin embargo, estos algoritmos de computación evolutiva con las indicaciones presentadas en esta tesis permiten pensar en la implementación de estas soluciones en tiempo real, incluso en problemas de control complejos.

Los ahorros económicos alcanzados utilizando algoritmos de control evolutivo en comparación con los convencionales hacen que sea atractiva su utilización en una gran cantidad de problemas complejos. FPC –PSO obtiene los mejores resultados por simulación en una planta real, que en comparación con el mejor GA obtiene por lo menos 1,1% de mejora en términos económicos.

Otro de los parámetros que tienen una gran influencia en el comportamiento del algoritmo PSO es la velocidad máxima y rango de variación máxima. Si es que no se sintoniza bien el algoritmo tiende a explotar por tener un rango muy amplio de búsqueda. Esto ocurrió mucho en la utilización de PSO con la caldera.

Además, la normalización de rangos es necesaria para la utilización del algoritmo PSO sin tener que generar grandes modificaciones en la programación.

Otro de los resultados importantes de acuerdo a los parámetros de PSO y GA es la cantidad de individuos/partículas que se utilizan para realizar una buena optimización. La **Tabla 12** presenta una mejora de precisión considerable, del orden de 15% en poblaciones mayores a 20.

Finalmente, se aplicaron exitosamente los algoritmos de computación evolutiva (SGA, NGA y PSO) para la resolución del problema de control predictivo. Este tipo de algoritmos presenta un desempeño inferior en series de tipo benchmark a un algoritmo LM basado en gradiente de segundo orden (Capítulo 4). En el caso de la aplicación principal de esta tesis se implementó FPC – PSO a una caldera de una planta termoeléctrica de ciclo combinado con resultados superiores a los otros algoritmos tradicionales y evolutivos tanto en tiempo computacional como en desempeño de la función económica implementada (Capítulo 5).

7. Referencias

Allgöwer, F., Badgwell, T., Qin, J., Rawlings, J., Wright, S. "Nonlinear predictive control and moving horizon estimation – an introductory overview", in *Advances in control: highlights of ECC'99*, P. Frank, Ed. London: Springer-Verlag, 1999, pp. 391–449.

Babuska, R., Sousa, J., Verbruggen, H. (1999). Predictive control of nonlinear systems based on fuzzy and neural models. Proceedings of the European Control Conference, ECC'99, August 31-September 3, Karlsruhe, Germany, pp. 667.

Bassett, S. and van Wijck, M. (1999) "Application of Predictive Control Technology at BP's Crude Oil Terminal at Grangemouth", The Institution of Electrical Engineers, London WC2R 0BL, UK.

Bauer, M. and Craig, I.K. (2008), "Economic Assessment of Advanced Process Control – A Survey and Framework", *Journal of Process Control* 18 (2008), pp. 2-18.

Bentsman, J., Tse, J., Manayathara, T., Blauwkamp, R., Pellegrinetri, G. (1994) "State space and frequency domain predictive controller design with application to power plant control." Proceedings of the third IEEE conference on control applications. Pp. 729-734

Bentsman, J., Tse, J., Pellegrinetri, G., Blauwkamp, R., (1995) "Application of stabilizing H2 predictive control to boilers." Proceedings of the IFAC Conference on Control of Power Plants and Power Systems. Pp. 189-194

Bouani, F. Laabidi, K. Ksouri, M.(2006) "Constrained Nonlinear Multi-objective Predictive Control." IMACS Multiconference on Computational Engineering in Systems Applications.

Bulut, B., Katebi, M. and Johnson, M. (2000) "Industrial Application of Model Based Predictive Control as a Supervisory System". Proceedings of the American Control Conference. Chicago, Illinois. 2000.

Camacho, E. y Bordons, C. "Model Predictive Control". Springer – Verlag. 1999.

Camacho, E. y Bordons, C. "Control Predictivo: Pasado, Presente y Futuro". IFAC 2004.

Causa, J., Karer, G., Núñez, A., Sáez, D., Škrjanc, I., Zupančič, B. "Hybrid Fuzzy Predictive Control Based on Genetic Algorithm for the Temperature Control of a Batch Reactor". *Computer & Chemical Engineering*, Volume 32, Issue 12, 22 December 2008, Pages 3254-3263.

Chen, X-s, Li, S-h, Zhai, J-v and Li, O. (2009), "Expert System based adaptive dynamic matrix control for ball mill grinding circuit", *Expert Systems with Applications* 36, 2009, págs. 716 - 723.

Clarke, D., Mohtadi, C., Tuffs, P. (1987) "Generalized Predictive Control(Parts I and II." *Automatica*, Vol. 23, N°2, pp. 137-160

Maurice Clerc and James Kennedy (1999) *The Particle Swarm: Explosion, Stability, and Convergence in a Multi-Dimensional Complex Space*. 2005 IEEE Transactions on Evolutionary Computation award

Coelho, J. P., de Moura Oliveira, P.B., and Boaventura Cunha, J. (2005). "Greenhouse air temperature predictive control using the particle swarm optimisation algorithm". In *Computers and Electronics in Agriculture* 49, 2005, pp. 330-344.

Contreras, J. (2004) "Diseño De Estrategias De Control Supervisor Usando Redes Neuronales Para La Caldera De Una Central Termica De Ciclo Combinado". Memoria para optar al Título de Ingeniero Civil Industrial, Ingeniero Civil Eléctrico. 2004.

Cutler, C., Morshedi, A., & Haydel, J. (1983). An industrial perspective on advanced control. In AICHE annual meeting, Washington, DC, October 1983.

Cutler C. R. y Ramaker B. L. (1979) *Dynamic Matrix Control – a computer control algorithm*. AICHE 86th National Meeting. Houston.

Das, S. (1995) *The polynomial neural network*, *Information Sciences* 87 (4) (1995) 231-246.

De Prada, C. (1997) "Fundamentos de Control Predictivo de Procesos". *Manuales de Ingeniería Química*, Capítulo 11, España, Marzo, págs. 141-146.

Dehuri, S., Cho, S.B. (2009) *Multicriterion Pareto based particle swarm optimized polynomial neural network for classification: A review and state of the art*, *Computer Science Review* (2009), doi:10.1016/j.cosrev.2008.11.002.

Del Valle, Y., Kumar, G., Mohagheghi, S., Hernandez, J.C., Harley, R., (2008) "Particle Swarm Optimization: Basic Concepts, Variants and Applications in Power Systems". *IEEE Transactions on Evolutionary Computation*, Vol. 12, N° 2, Abril 2008.

Dennis, J. E., and Schnabel, R.B. (1983) "Numerical Methods for Unconstrained Optimization and Nonlinear Equations", Englewood Cliffs, NJ. Prentice Hall. 1983.

Estévez, P., "Optimización Mediante Algoritmos Genéticos", *Anales del Instituto de Ingenieros de Chile*, Vol. 109, N° 2, Agosto 1997, pp. 83-92.

Fieldsend, J.E., Singh, S. (2002) *A multiobjective algorithm based upon particle swarm optimization, an efficient data structure and turbulence*, in: *Proc. UK Workshop on Computational Intelligence (UKCI.02)*, Birmingham, UK, 2002, pp. 37-44.

Flores, A., Sáez, D., Araya, J., Berenguel, M. and Cipriano, A. (2005) "Fuzzy Predictive Control of Solar Power Plant". *IEEE Transactions on Fuzzy Systems*. Vol. 13, N°1, February 2005.

Fogel, L., Owens, A. y Walsh, M. (1966) "Artificial Intelligence through Simulated Evolution". New York. Wiley. 1966.

Froisy, J. B., & Matsko, T. (1990). IDCOM-M application to the Shell fundamental control problem. AICHE annual meeting, November 1990.

Glover, F. (1989) "Tabu Search, Part I,"ORSAJ. Computing, Vol. 1, No. 3, pp. 190-206 (1989-summer)

Goldberg, D.E. (1989), "Genetic Algorithms in Search, Optimization and Machine Learning", Addison-Wesley, Reading, MA, 1989.

Grosdidier, P., Froisy, B., & Hammann, M. (1988). The IDCOM-M controller. In T. J. McAvoy, Y. Arkun, & E. Zafiriou (Eds.), Proceedings of the 1988 IFAC workshop on model based process control (pp. 31–36). Oxford: Pergamon Press.

Man Gyun Na In Joon Hwang Yoon Joon Lee (2006) "Design of a fuzzy model predictive power controller for pressurized water reactors." IEEE Transactions on Nuclear Science.

Hogg, B.W. El-Rabaie, N.M.(1990) "Generalized predictive control of steam pressure in a drum boiler." IEEE Transactions on Energy Conversion

Hogg, B.W. El-Rabaie, N.M.(1991) "Multivariable generalized predictive control of a boiler system." IEEE Transactions on Energy Conversion

Holland, J. (1965) "Adaptation in Natural and Artificial Systems". University of Michigan Press. 1965.

Holland, J.H. (1992). Adaptation in Natural and Artificial Systems. MIT Press, Second Edition.

Huzmezan, M.; Dumont, G.A.; Gough, W.A.; Kovac, S., "Adaptive control of delayed integrating systems: a PVC batch reactor," Control Systems Technology, IEEE Transactions on , vol.11, no.3, pp. 390-398, May 2003

Huzmezan, M.; Maciejowski, J.; (1998) "Reconfiguration and scheduling in flight using quasi-LPV high-fidelity models and MBPC control" American Control Conference, 1998. Proceedings of the 1998 Volume 6, 24-26 June 1998 Page(s):3649 - 3653 vol.6

Yingyi Jin, Chengli Su (2008) "Adaptive Model Predictive Control Using Diagonal Recurrent Neural Network" 2008 Fourth International Conference on Natural Computation

Kazemir Kargar, H., Aghmasheh, R., Safari, A. and Zareie Govar, G. R. (2008) "Multi-Agent-Based Particle Swarm Optimization Approach for PSS Designing in Multi-Machine Power Systems", 2nd IEEE International Conference on Power and Energy (PECon 08), December 1-3, 2008, Johor Baharu, Malaysia

Kennedy, J. Eberhart, R. (2001). Swarm Intelligence. Morgan Kaufmann Publishers. USA.

Kobayashi, T., Tani, T. and Miyamoto, S. (2000) Automation of Reformer Process in Petroleum Plant Using Fuzzy Supervisory Model Predictive Multivariable Control System. 2000.

Labbe, D., Hocking, B., Ray, B., Anderson, J., Klepper, P. (2006) Dynamic NO_x / Heat Rate Optimization. 16th Annual Joint Powid/EPRI Controls and Instrumentation Conference; 49th Annual ISA Powid Symposium, 4-9 June 2006, San Jose, California.

Lee, K.Y.; Heo, J.S.; Hoffman, J.A.; Sung-Ho Kim; Won-Hee Jung (2007) "Modified Predictive Optimal Control Using Neural Network-based Combined Model for Large-Scale Power Plants." Power Engineering Society General Meeting, 2007. IEEE Volume , Issue , 24-28 June 2007 Page(s):1 - 8

Lee, K. (1995) "Water level controls for a drum-type boiler system using fuzzy logic approach." Proceedings of the IFAC Conference on Control of Power plants and Power Systems, pp. 43-47

Liu, X. and Niu, L. (2008) "Feasible Constrained Nonlinear Predictive Control on Power Plant". 2008 American Control Conference. Washington, USA. 2008.

Love, J. (2007) "Process Automation Handbook, A guide to theory and practice." Springer.

Mahfoud, S.W. (1995). Niching Methods for Genetics Algorithms. Ph.D. Thesis, U. of Illinois at Urbana-Champaign.

Manayathara, T., bentsman, J., Pellegrinetti, G., Blauwkamp, R. (1994) "Application of stabilizing predictive control to boilers." Proceedings of the third Conference on Control Applications, pp. 1637-1642.

Marquis, P. y Broustail, J. P. (1998) "SMOC, a bridge between state space and model predictive controllers: Application to the automation of a hydrotreating unit", Proceedings of the 1998 IFAC workshop on model based process control, pp. 37-43, Oxford: Pergamon Press.

Marusak, P. M. (2008), "Advantages of an easy to design Fuzzy Predictive Algorithm in Control Systems of Nonlinear Chemical Reactors", Applied Soft Computing Journal, 2008, doi:10.106/j.asoc.2009.02.013.

Sáez, D., Milla, F., Ordys, A. "Hybrid Predictive Supervisory Control Based on Genetic Algorithms for a Gas Turbine of Combined Cycle Power Plants" European Control Conference 2007, Kos , Greece, July 2-5, 2007.

Miranda, V., and Fonseca, N., (2002) "EPSO Best-of—two-worlds Meta Heuristic Applied to Power System Problem", Proc. Of the IEEE Congress on Evolutionary Computation. Vol. 2, pp. 1080-1085, Jun. 2002.

Miranda V. and Naing Win Oo (2005), "Evolutionary Algorithms and Evolutionary Particle Swarms (EPSO) in Modeling Evolving Energy Retailers", 15th Power System Computation Conference, 2005, Liege, Belgium.

Moore, J., Chapman, R. (1999) Application of particle swarm to multiobjective optimization, Department of Computer Science and Software Engineering, Auburn University, 1999

Mori, H., Ohkawa, K. (2008) "Application of Hybrid Meta-Heuristic Method to Unit Commitment in Power Systems", 2008 IEEE Electrical Power & Energy Conference.

Nagarajan R. y Kumar, R.N. (2001) "A predictive fuzzy logic controller with an adaptive loop for the manufacture of resin adhesives". Computers & Industrial Engineering 39, págs. 145-158. 2001.

Narendra K. S. and Parthasarathy K. (1990). "Identification and Control of Dynamical Systems Using Neural Networks." IEEE Transactions on Neural Networks.

Nikolaev, N., Iba H. (2006) Adaptive Learning of Polynomial Networks, Springer, New York, 2006.

Núñez, A., Sáez, D., Oblak, S., Škrjanc, I. (2009) "Fuzzy-Model-Based Hybrid Predictive Control". ISA Transactions, Volume 48, Issue 1, January 2009, Pages: 24-31.

Onnen C.; Babuska R.; Kaymak U.; Sousa J.M.; Verbruggen H.B.; Isermann R.(1997) "Genetic Algorithms for optimization in predictive control." Control Engineering Practice, Volume 5, Number 10, October 1997 , pp. 1363-1372(10)

Ordys, A., A. Pike, M. Johnson, R. Katebi, y M. Grimble (1994) "Modelling and simulation of power generation plants". Springer-Verlag, Londres.

Parthasarathy, S., Gowan, H., Indhar, P. (1999), "Prediction of Flooding in an absorption Column using Neural Networks", Proceedings of the 1999 IEEE International Conference on Control Applications, Kohala Coast-Island of Hawaii, Hawaii, USA, 1999.

Peng, H., Ozaki, T., Haggan-Ozaki, V. And Toyoda, Y. (2002) "A Nonlinear Exponential ARX Model-Based Multivariable Generalized Predictive Control Strategy for Thermal Power Plants". IEEE Transactions on Control Systems Technology, Vol. 10, N° 2, March 2002.

Prett, D. M., & Gillette, R. D. (1980). Optimization and constrained multivariable control of a catalytic cracking unit. In Proceedings of the joint automatic control conference.

Qin, S.J., Badgwell, T.A. (2003) "A survey of industrial model predictive control technology." Control Engineering Practice 11. pp. 733-764

Ray, T., Liew, K.M. (2002) A swarm metaphor for multiobjective design optimization, Engineering Optimization 34 (2) (2002) pp.141-153.

Rechenberg (1994). "Evolutionsstrategie". Stuttgart. Frommann-Holzboog. 1994.

Richalet, J., Rault, A., Testud, J. L., & Papon, J. (1976). Algorithmic control of industrial processes. In Proceedings of the 4th IFAC symposium on identification and system parameter estimation. (pp. 1119–1167).

Sáez, D., Milla, F. and Vargas, L. (2007) “Fuzzy Predictive Supervisory Control Base don Genetic Algorithms for Gas Turbines of Combined Cycle Power Plants”. IEEE Transactions on Energy Conversion, Vol. 22, N°3, September 2007.

Richalet, J., Rault, A., Testud, J. L., & Papon, J. (1978). Model predictive heuristic control: Applications to industrial processes. Automatica, 14, 413–428.

Sáez, D., Zúñiga, R., Cipriano, A. “Adaptive Hybrid Predictive Control for a Combined Cycle Power Plant Optimization” International Journal of Adaptive Control and Signal Processing. Vol. 22, N° 2, pp.198-220, 2008.

Saez, D., Cipriano, A. and Ordys, A. (2000) “Optimisation Of Industrial Processes At Supervisory Level.” Springer. 2000.

Sánchez, L., Arroyo, F., García, M., Villavicencio, R. (1995) "Steam temperature fuzzy controllers in fossil power plant." Proceedings of the IFAC Conference on Control of Power Plants and Power Systems. Pp. 61-66.

Sánchez, L., Arroyo, F., Villavicencio, R. (1995a) "Dynamic matrix control of steam temperature in fossil power plants." Proceedings of the IFAC Conference on Control of Power Plants and Power Systems. Pp. 183-188.

Sarimveis, H., Bafas, G. (2003), “Fuzzy Model Predictive Control of non-linear processes using genetic algorithms”, Fuzzy Sets and Systems. pp. 59-80.

Schwefel, H-P (1965) “Kybernetische Evolution als Strategie der Experimentellen Forschung in der Strömungstechnik”. Diploma Thesis, Technical University of Berlin. 1965.

Schwefel, H-P (1995) “Evolution and Optimum Seeking”. New York, Wiley. 1995.

Shi, Y., Eberhart, R.C., (1998a). A modified particle swarm optimizer. In: Proc. IEEE Int. Conf. on Evolutionary Computation. Anchorage, AK, USA, pp. 69-73.

Shin S.C. and Park S. B.,(1998) GA – based predictive Control for Nonlinear processes. Electronics Letters. IEEE.

Skrjanc, I., Matko, D. (1994) “Fuzzy predictive controller with adaptive gain”, in Advances in model based predictive control, D. Clarke, Ed. Oxford, Great Britain: Oxford University Press, 1994, pp. 370–385.

Solís, J., Sáez, D., Estévez, P. “Particle Swarm Optimization-based Fuzzy Predictive Control Strategy”. 2006 IEEE World Congress on Computational Intelligence, International Conference on Fuzzy Systems Vancouver, Canada, pp. 8525- 8530, July 16-21, 2006.

- Song, Y., Chen, Z., Yuan, Z. (2007) "New Chaotic PSO-Based Neural Network Predictive Control for Nonlinear Process" IEEE Transactions on Neural Networks,
- Sugeno, M., Yasukawa, T. (1993). A fuzzy-logic-based approach to qualitative modeling. IEEE Transactions on Fuzzy Systems, Vol. 1, N° 1, February, pp. 7-31.
- Tadeo, F., Alvarez, T., Grimble, M.J. and Vilanova, R. (2002) "Implementation of Constrained Predictive outer-loop Controllers: Application to a Boiler Control System". 15th IFAC World Congress, Barcelona, Spain, July 2002.
- Tadeo, F. and Alvarez, T. (2008) "Implementation of Predictive Controllers as outer-loop Controllers". IET Control Theory and Applications. 2008.
- Takagi, T. and Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. IEEE Transactions Systems, Man and Cybernetics., Vol. SMC-15, pp. 116-132.
- Uduehi, D., Ordys, A. and Grimble, M. (2004) "State Estimation and the Equivalence of the Regulatory and Supervisory Predictive Control Law". Proceeding of the 2004 American Control Conference. 2004.
- de Oliveira, J.V. Lemos, J.M. (1994) Fuzzy model based long-range predictive control Fuzzy Systems, 1994. IEEE World Congress on Computational Intelligence., Proceedings of the Third IEEE Conference on
- Sy, M. V., Minh, P. X. (2008) Fuzzy model predictive control using Takagi-Sugeno model. Control, Automation and Systems, 2008. ICCAS 2008. International Conference on
- Vinsonneau, B., Goodall, D.P. and Burnham, K.J. (2005) "Hierarchical Supervisory Control and Plant Monitoring applied to industrial furnaces incorporating a priori knowledge". Proceedings of the 18th International Conference on Systems Engineering. 2005.
- Wang and Lagary (1995). Building Sugeno-type models using fuzzy discretization and orthogonal parameter estimation techniques. IEEE Transactions on Fuzzy Systems, Vol. 3 N°4, pp. 454-458.
- Wang, X., and Xiao, J. (2005) "PSO-Based Model Predictive Control for Nonlinear Processes." Lecture Notes in Computer Science, pp. 196-203
- Win Oo, N., (2008) "A comparison Study on Particle Swarm and Evolutionary Particle Swarm Optimization using Capacitor Placement Problem", 2nd IEEE International Conference on Power and Energy (PECon 08), December 1-3, 2008, Johor Baharu, Malaysia.
- Wong, C. H., Shah, S. L, Bourke, M. M. and Fisher, D. G. (2000) "Adaptive fuzzy relational predictive control". Fuzzy Sets and Systems Volume 115, Issue 2,

Yoo, S.C., Kim, T. G., Choi, B.G., Yoon, J.K., Seo, S.T. and Kim, H.S. (2006) "Optimized Model Predictive Control of Commercial BTX Plant using Profit Controller", SICE-ICASE International Joint Conference 2006, Bexco, Busan, Korea, Oct. 18-21, 2006.

Yuzgec, U., Becerikli, Y., Turker, M. (2006) "Nonlinear predictive control of a drying process using genetic algorithms " ISA Transactions Volume 45, Issue 4, October 2006, Pages 589-602

Zhang, Y. Jia, L. and Liu, H. (2007) "An Intelligent Supervisory System for the Thermal Process during Severe Disturbance". Proceedings of the IEEE International Conference on Automation and Logistics. China. 2007.

Zhiteckij, L., Skurikhin, V., Procenko, N., Sapunova, N. (1995) "Design of an adaptive robust and careful controller for a thermal power plant. " Proceedings of the IFAC Conference on Control of Power Plants and Power systems, SIPOWER '95. pp. 221-226

Zhixiang, H., Hui, C., Heqing, L. (2008) "Neural networks predictive control using AEPSO." 27th Chinese Control Conference, 2008. CCC 2008.

8. Anexos

I. Identificación de Series

I.1. Introducción

En el presente anexo se presentarán los resultados de la identificación de las diferentes series utilizadas en el **Capítulo 4**.

I.1.1. Identificación Serie 1

Esta serie es no lineal en la salida y lineal en la entrada. Los resultados de aplicación a esta serie fueron publicados en Solís *et al.* (2006).

$$f[y(k+1)] = \frac{y(t-1)y(t-2)(y(t-1)+2.5)}{1+y^2(t-1)+y^2(t-2)} \quad (47)$$

f es función no lineal.

Se utilizan los regresores que recomienda la estructura del modelo, es decir, con 2 autorregresores y un regresor en la entrada.

Las reglas del modelo difuso T&S es de la siguiente forma:

$$\begin{aligned} &\text{if } y(t-1) \text{ is } A_1 \text{ and } y(t-2) \text{ is } A_2 \text{ and } u(t-1) \text{ is } A_3 \\ &\text{then } y(t) = g_0 + g_1 y(t-1) + g_2 y(t-2) + g_3 u(t-1) \end{aligned} \quad (48)$$

Se determina el número de reglas mediante un procedimiento de clustering difuso.

Los parámetros de los conjuntos difusos (funciones gaussianas) definidos en la **Ecuación (48)** y los parámetros de las consecuencias se entregan en las **Tablas 14 y 15**.

$$\mu_i^j = e^{\left(-0.5 \cdot \left(a_i^j \cdot (x - b_i^j)\right)^2\right)} \quad (49)$$

donde i es el número de regla y j representa a qué regresor es en el modelo. El parámetro a_j^i , representa el ancho de las funciones gaussianas de los conjuntos difusos; los parámetros b_j^i son los centros de las funciones gaussianas; en tanto, los parámetros g_k^i son los correspondientes a las consecuencias lineales.

Tabla 14. Parámetros a y b de los conjuntos difusos.

Regla i	a_1^i	a_2^i	a_3^i	b_1^i	b_2^i	b_3^i
1	0,016351	0,05752	0,020583	2,044	-12,168	34,611
2	0,050537	0,019496	0,018099	11,436	28,961	7,2089
3	0,019492	0,026353	0,017381	40,796	-26,505	7,0477
4	0,015736	0,015763	0,01728	0,31792	0,3622	0,089685
5	0,015406	0,039542	0,017337	16,943	-4,5831	3,8711
6	0,027535	0,015734	0,018073	-1,2572	21,962	4,9088
7	0,019781	0,014596	0,015316	-6,5882	9,2874	1,076

Tabla 15. Parámetros g de la salida lineal de los modelos difusos.

Regla i	g_0^i	g_1^i	g_2^i	g_3^i
1	13,818	0,06569	0,12882	0,83397
2	-43,015	0,88925	-0,29678	1,0733
3	-56,289	0,23448	0,13451	0,93961
4	-5,9218	0,009998	0,79584	0,99782
5	-15,794	0,26697	2,9154	1,028
6	63,208	0,42956	-1,2939	1,0705
7	24,006	-0,019816	0,18813	0,99729

Una vez obtenidos los parámetros del modelo difuso se procede a realizar la simulación a partir de los modelos difusos T&S mediante predicción a 1 y 10 pasos.

La comparación será con los modelos lineales del tipo ARX, obtenido en la **Ecuación (50)** y presentados en las **Figuras 28** sus comportamientos a 10 pasos, respectivamente.

$$y(t) = -0.0004251y(t-1) + 0.3158y(t-2) + 1.003u(t-1) \quad (50)$$

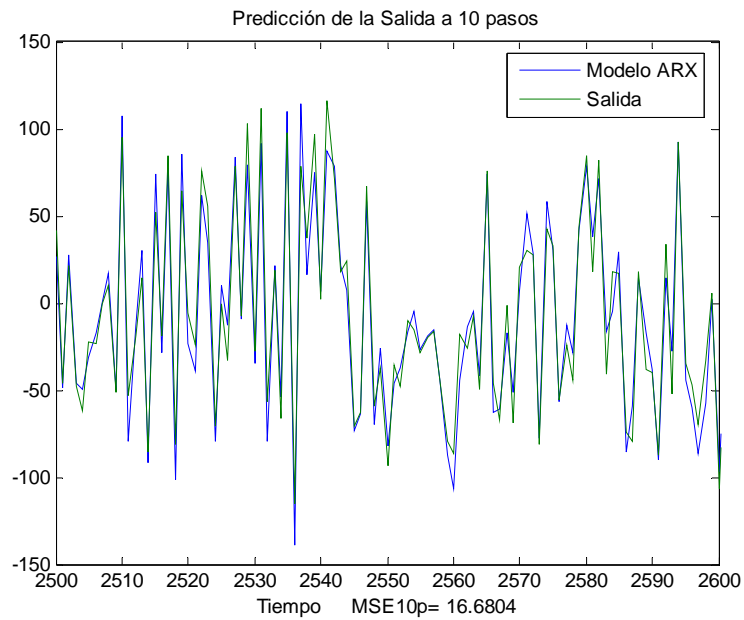


Figura 28. Identificación mediante modelo lineal ARX. Error a 10 pasos = 16.6804.

La **Figura 29** muestra los resultados a 10 pasos de los modelos difusos T&S.

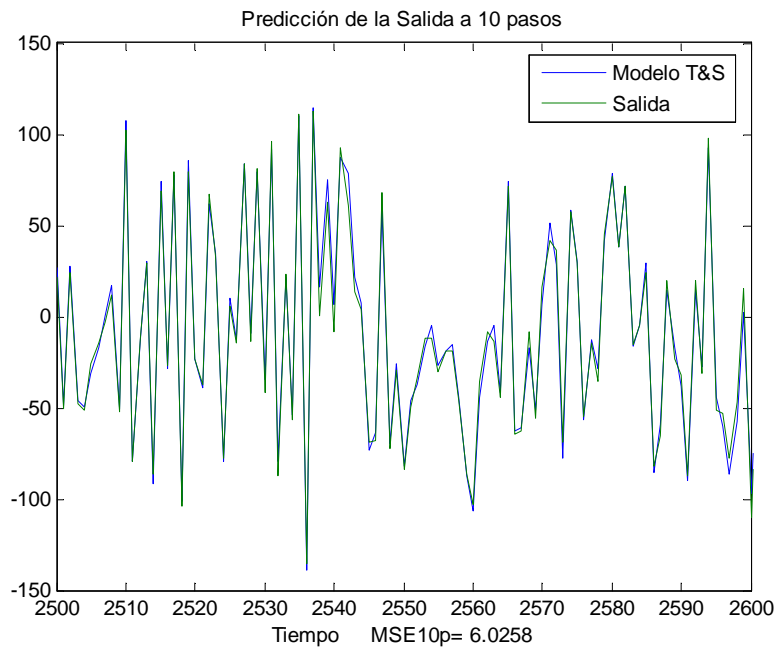


Figura 29. Identificación mediante modelo difuso T&S. Error a 10 pasos = 6.0258.

A partir de los resultados gráficos y mediante la **Tabla 16** se pueden ver las mejoras que se obtienen de la utilización de los modelos difusos T&S, donde la mejora porcentual es de un 323% a 1 paso y 277% a 10 pasos, comprobándose la solidez de la modelación difusa en comparación con los modelos lineales.

Tabla 16. Error a 1 y 10 pasos para modelo lineal ARX y difuso T&S.

	Modelo ARX	Modelo Difuso T&S	Mejora Porcentual
Error a 1 Paso	16,0608	4,9703	323%
Error a 10 pasos	16,6804	6,0258	277%

1.1.1.1. Identificación Serie 2

En esta serie en particular, la entrada a dicha planta tiene un comportamiento no lineal con respecto a la salida:

$$f[y(k+1)] = \frac{y(k)}{1 + y(k)^2}, \quad (51)$$

f no lineal

Además, la planta presenta también un comportamiento no lineal con respecto a la salida:

$$g[u(k+1)] = u(k)^3, \quad g \text{ no lineal} \quad (52)$$

Se identifica con un regresor para la entrada y uno para la salida debido a la estructura de la planta. El procedimiento de clustering difuso entrega un número de 5 reglas. La estructura del modelo difuso T&S será la siguiente:

$$\text{if } y(t-1) \text{ is } A_1 \text{ and } u(t-1) \text{ is } A_2 \text{ then } y(t) = g_0 + g_1 y(t-1) + g_2 u(t-1) \quad (53)$$

Los parámetros de los conjuntos difusos y de los parámetros de las consecuencias se entregan en las **Tablas 17 y 18**, respectivamente.

Tabla 17. Parámetros a y b de los conjuntos difusos.

Regla i	a_1^i	a_2^i	b_1^i	b_2^i
1	0,31269	1,247	-2,5623	-0,37782
2	0,3453	6,4443	0,025689	1,7436
3	0,71266	1,4663	-0,042404	0,030118
4	0,34186	6,4779	-0,07165	-1,7432
5	0,32431	1,2415	2,3258	0,27189

Tabla 18. Parámetros g de la salida lineal de los modelos difusos.

Regla i	g_0^i	g_1^i	g_2^i
1	-0,36178	-0,018336	1,5739
2	-8,8433	0,19907	8,8043
3	-0,025896	1,2666	-0,2875
4	9,8889	0,20855	9,4647
5	0,48546	-0,046004	1,4873

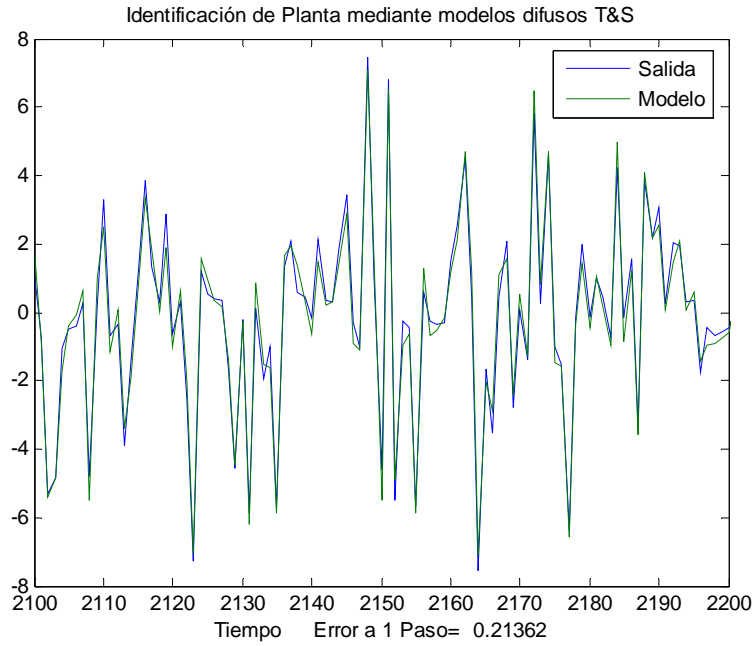


Figura 30. Identificación mediante modelo difuso T&S. Error a 1 paso = 0.21362.

En las **Figuras 30 y 31** se presentan los comportamientos a 1 y 10 pasos del modelo difuso.




Figura 31. Identificación mediante modelo difuso T&S. Error a 10 pasos = 0.46445.

El modelo lineal ARX identificado en las mismas condiciones (un regresor en la salida y uno en la entrada) es el siguiente:

$$y(t) = 0.05695y(t-1) + 2.396u(t-1) \quad (54)$$

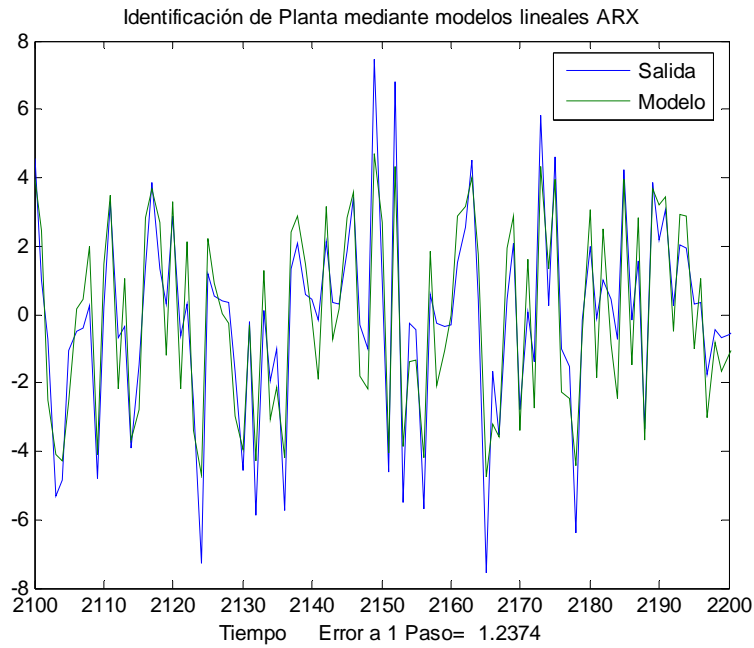


Figura 32. Identificación mediante modelo lineal ARX. Error a 1 paso = 1.2374.




Figura 33. Identificación mediante modelo lineal ARX. Error a 10 pasos = 1.2295.

Los resultados obtenidos a partir de la identificación lineal ARX se muestran en la **Figuras 32 y 33**.

En la **Tabla 19** presenta el resumen de errores a 1 y 10 pasos para el modelo lineal ARX y el difuso T&S.

Tabla 19. Error a 1 y 10 pasos para modelo lineal ARX y difuso T&S.

	Modelo ARX	Modelo Difuso T&S	Mejora Porcentual
Error a 1 Paso	1,2374	0,21362	579%
Error a 10 Pasos	1,2295	0,46445	265%

En dicha tabla se puede ver que el modelo difuso T&S presenta un mejor desempeño a 1 y 10 pasos.

II. Centrales Termoeléctricas de Ciclo Combinado⁵

II.1. Introducción

En el actual mercado energético la eficiencia es una obligación. Los recursos energéticos no renovables son cada vez más escasos con la consecuente alza de sus precios. Es por esto que el mercado y los países están apostando cada vez más por estrategias en las que la matriz energética ha incorporado energías renovables que permitan el autoabastecimiento y en algunos casos, el comercio.

En este contexto es que las plantas tradicionales que utilizan combustibles fósiles tienen un gran desafío para ser competitivas. Las centrales termoeléctricas de ciclo combinado aún se consideran una buena opción debido a que permiten operar con costos bajos y ser más eficientes que los ciclos por sí solos. El rendimiento térmico global varía entre 74% y 78%.

Las centrales de ciclo combinado que serán consideradas en esta tesis utilizan conjuntamente una turbina a gas y una a vapor. Las turbinas a gas tienen una gran eficiencia en presencia de altas temperaturas. Las turbinas a vapor por el contrario presentan un mejor comportamiento en ciclos de bajas temperaturas. La turbina de gas genera gases de escape a altas temperatura que se utilizan para generar vapor que acciona una turbina de vapor. Ambas turbinas accionan generadores eléctricos. Mediante este uso se logra aprovechar más del 50% de la energía del combustible para generar energía eléctrica. la potencia total obtenida es la suma de la potencias de la turbina de gas y de vapor.

⁵ Este capítulo se basa en las siguientes publicaciones: Álvarez *et al* (2005), Sáez *et al* (2002) y Ordys *et al* (1994)

El mayor interés del uso de este tipo de centrales se refiere a la generación de energía eléctrica. Las potencias de estas plantas pueden variar entre los 60 y 2000 MW.

La producción de energía térmica es también importante en este tipo de centrales, con potencias menores a los 60 MW. Potencias inferiores a 5 MW no suelen ser rentables.

II.2. Análisis Termodinámico

Tal como se mencionó previamente, en este tipo de centrales se combina el uso de una turbina de gas y una de vapor. La turbina de gas responde a un ciclo de Brayton y la de vapor a un ciclo de Rankine. Termodinámicamente se considera el uso de dos máquinas térmicas combinadas entre sí como se muestra en la **Figura 34**. El calor del ciclo superior (Q_s) con rendimiento η_s es el que hace funcionar la máquina inferior con rendimiento η_i .




Figura 34. Máquinas Térmicas en un Ciclo Combinado

El trabajo producido en el ciclo superior es W_s y el del inferior es W_i , como se ve en las siguientes relaciones:

$$W_s = \eta_s \times Q$$

$$W_i = \eta_i \times Q_s$$

Se puede relacionar Q y Q_s , como:

$$Q_s = Q (1 - \eta_s)$$

el trabajo total que se genera es la suma de ambos:

$$W = W_s + W_i = Q (\eta_s + \eta_i - \eta_s \times \eta_i)$$

el rendimiento térmico de la planta de ciclo combinado es:

$$\eta_T = W/Q = Q (\eta_s + \eta_i - \eta_s \times \eta_i) / Q = \eta_s + \eta_i - \eta_s \times \eta_i$$

en esta expresión se ve la ganancia de utilizar este ciclo. El rendimiento térmico del ciclo superior aumenta en $\eta_i (1 - \eta_s)$ cuando el calor cedido es utilizado para producir trabajo adicional en el ciclo de menor temperatura.

En un diagrama T-S se representan ambos ciclos:




Figura 35. Diagrama T-S de un Ciclo Combinado.

II.3. Características de Centrales Termoeléctricas de Ciclo Combinado

Las centrales termoeléctricas de ciclo combinado se clasifican de acuerdo a la configuración existente entre las turbinas (Ordys *et al.*, 1994):

- *Configuración estándar:* Los gases de escape de la turbina de gas se utilizan para producir vapor en la Caldera Generadora de Vapor por Recuperación de Calor (HRSG, Heat Recovery Steam Generator). La HRSG extrae el calor proveniente de los gases de escape de la turbina de gas para alcanzar los parámetros de vapor (Temperatura y Presión). La turbina de gas juega el rol principal en la producción de electricidad.
- *Configuración de Ciclo con bajo exceso de aire:* Los gases de escape de la turbina de gas proveen aire a la cámara de combustión de la caldera, la turbina de vapor es la que juega el principal rol en la producción de electricidad (80 - 85%).
- *Configuración con Caldera con Combustión adicional:* En este tipo de centrales se considera una fuente adicional de calor para la caldera que permita aumentar la generación de vapor. La eficiencia eléctrica puede ser menor que en otro tipo de configuraciones pero la incorporación de esta combustión adicional agrega flexibilidad de operación y no solo es dependiente de la turbina de gas.
- *Configuración de Acción Reversa:* En este tipo de configuración, el flujo de calor se devuelve en el sentido que el calor es transportado desde la parte de vapor (la caldera) hacia la parte de gas. La turbina de gas se abastece de gas o de aire limpio. La turbina de vapor juega el rol principal en la producción de electricidad.

La configuración que se utilizará en este trabajo es la estándar (**Figura 36**).

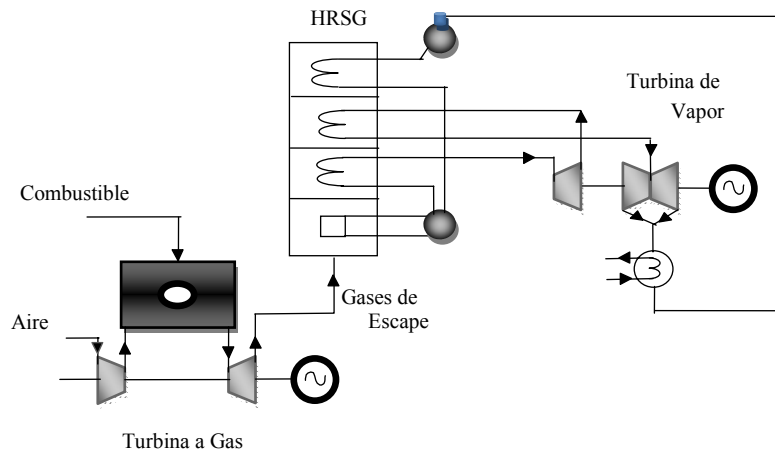


Figura 36. Planta de Ciclo Combinado en Configuración Estándar.

Los principales componentes para este tipo de configuraciones son los siguientes:

- Turbina de Gas:
 - Cámara de Combustión
 - Compresor
 - Suministro de Aire y Combustible
 - Generador
- Turbina de Vapor con Generador.
- HRSG
 - Suministro de Calor Adicional (Opcional)
 - Suministro de aire y combustible (Solo para HRSG con Calor Adicional)
- Condensador
- Sistema de Agua de Alimentación para la Turbina de Vapor
- Sistema de Piping junto con las válvulas, bombas de vapor, compresores de aire, estanques de agua.

II.3.1. Principales Componentes de Centrales Termoelectricas de Ciclo Combinado

II.3.1.1. Turbina de Gas

Esta Turbina produce electricidad por medio de la combustión de algún gas. Este proceso se realiza en la cámara de combustión donde reacciona el gas con el aire comprimido en el compresor. Esencialmente en la turbina se transforma la energía interna del combustible en energía mecánica (**Figura 37**).

Las Turbinas de Gas en una planta de ciclo combinado producen, además de la energía eléctrica, un flujo de calor que está contenido en los gases de escape de la combustión. Este flujo es el que permite la interconexión con la Turbina de Vapor, puesto que los gases circulan con una temperatura alta que permite el intercambio de calor por medio de la HRSG con el flujo de líquido y vapor que forma el circuito que alimenta a esta turbina.

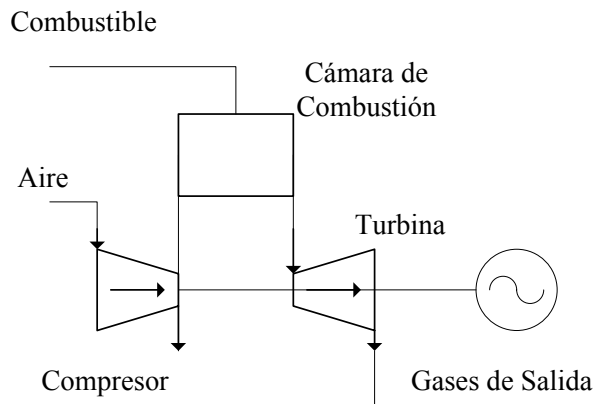


Figura 37. Turbina de Gas

II.3.1.2. Turbina de Vapor

Algunas turbinas de vapor son las siguientes:

- de Vapor Condensado: El vapor sale de la turbina casi en condiciones de vacío e ingresa al condensador.

- de Presión Contraria: El vapor sale de la turbina, a una presión dada, puede ser utilizado más adelante (por ej. para calentar).
- de Reducción: Una parte del vapor es dirigido para bypassear la turbina y puede ser usado más adelante.
- de Extracción: una parte de vapor se extrae desde la turbina en una etapa dada y puede ser usado más adelante.
- de Recalentamiento: Una parte del vapor se extrae en una etapa dada y luego es recalentado en la caldera y es reintroducido en la turbina.
- de Doble Presión: La turbina consiste de dos partes (dos turbinas trabajando en un shaft común), una de alta presión y una de baja presión. Esto se refiere a la presión de vapor en el ingreso a la turbina. La parte de baja presión consiste normalmente en turbinas gemelas por lo que habrán 3 turbinas girando en el mismo shaft.
- de Triple Presión: similar a la anterior pero se le agrega una turbina de presión intermedia.

El tipo de Turbina de Vapor considerada en esta tesis es de doble presión, tal como se observa en la **Figura 38**.

Las variables más importantes son las siguientes:

- Parámetros del Vapor: Presiones y Temperaturas al ingreso y salida de la turbina.
- Parámetros eléctricos del generador.
- Parámetros de Seguridad.

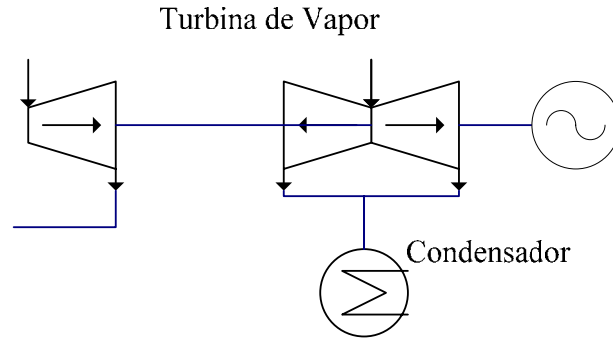


Figura 38. Turbina de Vapor

II.3.1.3. Caldera

Es la encargada de producir el vapor que alimentará la turbina de vapor. Según sea la fuente de calor que la alimente se pueden clasificar en:

- Calderas con Calor suplementario,
- Caldera sin Calor suplementario (HRSG).




Figura 39. Heat Recovery Steam Generator

Uno de los atractivos que tienen las plantas de ciclo combinado es que en la etapa en la que interviene el HRSG y la Turbina de Vapor se utiliza agua debido a su abundancia, su fácil manejo, el reducido costo, y sus buenas propiedades, de las que destacan:

- Alto calor específico
- Alto calor latente en el rango normal de temperaturas de utilización, lo que significa
- utilizar menores cantidades de agua para transportar la misma cantidad de energía
- Conductividad térmica relativamente alta
- Viscosidad relativamente baja
- Temperatura crítica razonablemente alta, permitiendo su empleo en ciclos térmicos con bajas exigencias relativas de energía para la compresión o el bombeo.

El vapor tiene características similares al gas (varía notablemente su volumen específico con la presión, además de expandirse o difundirse indefinidamente con las únicas limitaciones de las fuerzas gravitatorias (peso) o de las paredes del recipiente que les contiene) cuanto más seco y sobrecalentado es, aunque normalmente está en una situación muy cercana a la coexistencia de líquido y gas, es decir, cerca de la condensación. Por eso se dice que un vapor es tanto más gas cuanto más sobrecalentado se encuentra. El agua que se puede obtener en ríos, pozos y lagos no puede utilizarse directamente, por contener sustancias disueltas y contener aire disuelto, por lo que deberá ser tratada previamente a su utilización. La caracterización de la calidad del agua se obtiene a partir de la definición de su dureza, que hará referencia a la cantidad total de calcio y magnesio que contiene disuelta.

Para cada caldera existe un tratamiento adecuado del agua, que es consecuencia de las exigencias de calidad de agua en la caldera, entre otros.

El agua de alimentación de la caldera se compone del condensado (vapor convertido en agua después de haber pasado por la turbina), y se complementa con el agua de reposición (agua ablandada) para compensar pérdidas. En centrales termoeléctricas el agua en bruto (directa) representa tan sólo el 0,5% del agua total que entra en la caldera, mientras que en casos en que se

utilizan turbinas a contrapresión, ésta representa el 100%, ya que se utiliza para otros procesos el vapor descargado por la turbina.

La tendencia a la corrosión de la caldera causada por el agua de alimentación está determinada por dos factores:

- La acidez (pH), que fijara la velocidad de ataque de las paredes.
- El contenido de oxígeno, que fija el alcance de este ataque, por lo que será necesario desgasificar el agua de alimentación antes de que entre a la caldera.

La purga es un flujo de agua expulsado de la caldera para mantener un contenido de sales determinado dentro de ella, para evitar una concentración excesiva de los sólidos disueltos por la explotación, así como para dar salida a los sólidos que pudiera haber en suspensión. La purga provoca pérdidas de calor, incluso cuando se aprovecha el calor del agua evacuada.

Además existe una serie de equipos auxiliares encargados de proporcionar el agua de alimentación, los combustibles y el aire de combustión en las cantidades y condiciones adecuadas, aparte de extraer de las calderas los gases producidos, las purgas y otros.

1. Equipos del carbón y combustible sólido

El carbón puede quemarse según dos técnicas: triturado o pulverizado. Cada una de ellas requiere una preparación del combustible y unos equipos específicos para la alimentación del carbón al hogar de la caldera. En el caso de quemar carbón triturado, la combustión deberá realizarse en las parrillas, y el carbón deberá ser triturado previamente.

Si se utiliza carbón pulverizado, los quemadores introducen el carbón y el aire de combustión de forma que se produzca una llama estable y a distancia del quemador. Su buen funcionamiento requiere una mezcla rápida y eficiente del combustible y del aire, y que los gases sean dirigidos a una velocidad apropiada para que el volumen total del hogar sea útil y no existan zonas muertas.

2. Accesorios de combustibles líquidos

El quemador es el encargado de introducir el combustible dentro de la caldera y debe cumplir unos requisitos mínimos, como son:

- Convertir el líquido en gas a vapor.
- Provocar una buena mezcla entre vapor y aire.
- Elevar la temperatura de la mezcla por encima de la temperatura de ignición
- Asegurar la continuidad de la alimentación de aire y combustible.
- Posibilitar la evacuación de los productos de la combustión fuera del hogar.
- Ser regulable para poder atender diversos valores de carga.

3. Combustibles gaseosos

Se queman y regulan con mayor facilidad, por lo general, ya que no existen problemas de pulverización para la posterior gasificación, como en los combustibles sólidos o líquidos. Los gases son generalmente limpios y, por consiguiente, no forman atascos ni ensucian las cámaras de combustión.

4. Tiro

Al quemar un combustible en hogar de una caldera éste se llena de productos de la combustión. Entonces es necesario eliminar esta atmósfera y hacer penetrar aire nuevo que permita que la combustión prosiga. El gas, a elevada temperatura, tiende a ascender y el lugar que va dejando tras de sí en el hogar es ocupado por el aire que penetra por si mismo, estableciendo una corriente que recibe el nombre de tiro. Esta corriente puede ser natural o bien artificial, con la ayuda de un ventilador. Los ventiladores pueden usarse como aspiradores, para extraer los gases del hogar (tiro inducido) o como impulsores de aire produciendo sobrepresión (tiro forzado).

5. Equipos de depuración de gases

La pureza del humo expulsado de la caldera a través de la chimenea debe cumplir, como mínimo, con la reglamentación, con tal de respetar al máximo el medio ambiente. En concreto deben eliminarse del humo las partículas sólidas que lleva en suspensión tales como trocitos de carbón, cenizas y hollín, por lo que se hace el gas por los depuradores de humos, como pueden ser:

- El lavador de gas, que obliga al humo a desviarse en ángulo recto y a ponerse en contacto con el agua, para privarlo de sustancias sólidas.
- Ciclón, en el cual el humo adquiere un movimiento centrífugo, que consigue arrebatarse al gas un porcentaje muy elevado de partículas sólidas.
- Precipitador electrostático, que alcanza rendimientos en torno al 99%, y donde el gas atraviesa un campo electrostático, que produce que las partículas en suspensión, cargadas eléctricamente, sean desviadas de su trayectoria por el efecto del campo. Este tipo de precipitador consume mucha menos energía que los separadores ciclónicos, aunque son de un costo más elevado

II.3.1.3.i. Tipos de Calderas

La caldera se define como un generador de vapor de fuego directo. El combustible utilizado puede ser líquido, gaseoso o sólido.

La combustión tiene lugar fuera de la región de ebullición del agua, concretamente en el fogón o cámara de fuego. Para mantener la combustión es necesario suministrar cierta cantidad de aire y remover los productos resultantes de la combustión mediante el tiro. La capacidad de producción de calor depende de:

- El grado de combustión del combustible
- La extensión de la superficie de calefacción

- Las áreas de calefacción primarias (calor transmitido por radiación) y las áreas secundarias (por convección)
- La circulación por agua y vapor
- La circulación de los gases de combustión.

El funcionamiento de las calderas se basa en calentar el agua de un circuito hasta el punto de ebullición, de modo que el vapor se acumula en la parte más alta del circuito de fluido de la caldera, por tener densidad menor a la del agua. La caldera se alimenta de modo que el nivel del agua se mantiene más o menos constante. Las calderas más frecuentes para las Turbinas de Vapor son las de acero, las de lecho fluidizado y los reactores nucleares.

1. Calderas de acero. Tipo pirotubular

Éste es el primer tipo de caldera de acero, y ésta formada por tubos rectos que contienen los gases de la combustión, y que calientan el agua que rodean los tubos. El fogón de la caldera puede ser externo o interno.

Dentro de las calderas de fogón interno podemos distinguir entre:

- Calderas Horizontales tubulares escocés
- Calderas Verticales tubulares
- Calderas de tipo residencial




Figura 40. Caldera Pirotubular

Las más usadas en la industria son las horizontales tubulares (**Figura 40**), con tamaños de hasta 6800 kg de vapor a la hora. Algunas características son:

- Poseen un gran volumen de almacenamiento de agua, que compensa los efectos de las fluctuaciones de la demanda de vapor.
- Bajo costo si las comparamos con las acuotubulares.
- Necesitan más tiempo para alcanzar su presión y temperatura de trabajo que las acuotubulares.

2. Calderas de acero. Tipo Acuotubulares

Como su nombre indica, están formadas por tubos y colectores que contienen el agua, bien sea en estado líquido o vapor, durante su paso por la caldera. Los domos, que están interconectados por los tubos tienen la misión de almacenar agua y vapor. Normalmente hay dos, tres o cuatro colectores, y generalmente uno de ellos se encuentra a menor altura que los otros, y contiene una válvula de purga para evacuar. Los superiores son colectores de agua y vapor, y en su interior llevan separadores de vapor, para eliminar el arrastre de humedad, y un precipitador, purificando así el vapor. Los tubos son la única superficie de calefacción.

Este tipo de caldera puede tener la disposición de los tubos rectos o en forma curvada, presentando esta última disposición mejores características de presión y temperatura, con lo que ha desplazado a las de tubos rectos.

Algunos de los accesorios de la caldera acuotubular son:

- El economizador, que aprovecha los gases finales para calentar el agua de alimentación de la caldera antes de que se mezcle con la que circula por interior de la caldera.
- Calentador de aire, antes de que éste participe en la combustión.
- Sobrecalentador, que aumenta la temperatura que proviene de la caldera, antes de que éste entre en la turbina.
- Recalentador, Que también aumenta la temperatura del vapor, pero éste procede ahora de una primera expansión en la turbina.





Figura 41. Caldera Acuotubular

3. Calderas de lecho fluidizado

La fluidización es una operación en la que un sólido se pone en contacto con un líquido o un gas (el caso más usual), adquiriendo el conjunto unas características similares a las de los fluidos.

El lecho está constituido por una capa de material sólido en partículas (carbón pulverizado), soportada inicialmente por una placa porosa, a través de la cual se inyecta el gas en sentido ascendente. Al pasar a través del sólido, el aire de alimentación experimenta una pérdida de presión, pero fluye en régimen turbulento y alta velocidad a la salida del soporte poroso. El

aire en estas condiciones dispone de suficiente energía como para arrastrar las partículas de combustible sólido hasta una cierta altura.

Dado que en el recinto ya existe combustión de partículas anteriores, las que se van aportando se queman, incluyendo gran variedad de calidades de combustible sólido, suspendido en la corriente turbulenta y ascendente del aire de combustión, que asciende desde abajo del lecho y generalmente está mezclado con caliza para absorber el azufre.

Se pueden diferenciar distintos estados de operación básicos:

- Lecho fijo o empaquetado. El aire atraviesa el lecho a baja velocidad, con lo que la fuerza que produce éste es menor que el peso de las partículas, y el fluido pasa por los espacios entre partículas.
- Lecho incipientemente fluidizado. El fluido pasa a una velocidad mayor, produciendo una fuerza que se iguala aproximadamente con el peso de las partículas. Llegados a este punto el lecho se expande al tiempo que se inicia el arrastre de partículas, sobretodo las más finas.
- Lecho fluidizado circulante. La velocidad del fluido es aún mayor, y se produce el arrastre del lecho. Pueden ocurrir dos cosas, la primera es que el lecho consigue el equilibrio al verse aumentada la distancia entre partículas (lecho homogéneamente fluidizado), y la otra es que se origina una burbuja en el seno del lecho, sin que varíe la distancia entre las partículas (lecho heterogéneamente fluidizado o burbujeante).
- Transporte neumático, se produce al seguir aumentando la velocidad del fluido, y en este caso el lecho fluidizado propiamente dicho ya no existe, porque se arrastran todas las partículas.

En los dos últimos casos hace falta un ciclón para la recuperación de partículas. En el ciclón, estructura las grandes dimensiones, el fluido se hace recircular. El ciclón tiene que estar revestido de un material refractario para soportar las altas temperaturas.

Las características del lecho fluidizado en operaciones industriales son las siguientes:

- Permite operaciones de control con sencillez.
- Se puede generar cantidades próximas a las de 100 toneladas por hora de vapor.
- Permite eliminar el SO₂ de los gases de combustión.
- La mezcla rápida de sólidos conlleva unas condiciones cercanas a tener una temperatura constante en todo el reactor. Ello permite un control sencillo y seguro.
- Hace posible evacuar las grandes cantidades de calor producidas.
- Es posible utilizarlo para operaciones de gran escala.
- Las transferencias de calor y de masa entre el gas y las partículas es grande.
- Alguna desventaja sería la erosión de las tuberías y depósitos por abrasión de partículas, que puede ser seria.
- Instalación generalmente capaz de aceptar combustible de baja calidad, aunque está diseñado normalmente para un tipo de combustible específico.
- La combustión en el lecho tiene un campo limitado de operación, dentro del cual el lecho esta en equilibrio, por lo que en general está diseñado para cargas constantes.




Figura 42. Caldera de Lecho Fluidizado

II.3.1.3.ii. Combustibles para Calderas de Vapor

Pueden emplearse combustibles sólidos, líquidos y gaseosos. El empleo de uno u otro depende de la disponibilidad del país dónde se halla instalada la caldera.

La combustión sólida se realiza a partir del carbón, generalmente pulverizado. El carbón más usado es la hulla, con un contenido de carbono del 85%

Como líquidos, se usan los derivados del petróleo y muy especialmente los fuel-oils. También es posible aprovechar los productos negros resultantes de la destilación del petróleo, que aun siendo de difícil manejo y elevada viscosidad poseen un poder calorífico alto.

Combustibles gaseosos empleados son el gas natural, el gas del carbón, propano, etc. El gas natural es de un uso más fácil y limpio, por lo que es totalmente recomendable su utilización si se poseen cantidades suficientes. La gasificación del carbón permite una combustión con gases más limpios que el carbón en sí, ya que suele eliminarse la mayor parte del azufre. El gas propano es de uso más limitado, puesto que resulta más caro.

Sobre la combustión, es esencialmente lo mismo que para las turbinas de gas.

II.3.2. Principales Características de los Modelos Utilizados

II.3.2.1. *Turbina de Gas*

Para el desarrollo de este modelo se hacen los siguientes supuestos:

- El aire y otros productos de la combustión se pueden considerar como gases ideales,
- Los calores específicos se asumen constantes para los productos de la combustión, aire y otros.
- Un proceso politrópico, adiabático uniforme describe el flujo a través del compresor y la turbina.
- Los retardos de transporte en los componentes son pequeños por lo que se pueden aplicar ecuaciones en estado estacionario.
- La energía cinética de ingreso del gas que fluye dentro del compresor y la turbina es despreciable.
- El flujo de la masa de aire a través del compresor se controla a través de deflectores de aire de ingreso (Inlet Guide Vanes, IGVs)
- La formación de NO_x y CO se modela como una función de la razón vapor/combustible.

II.3.2.2. *Turbina de Vapor*

Las ecuaciones se obtienen de acuerdo a los siguientes supuestos:

- El vapor sobrecalentado se trata como un gas ideal.
- Las etapas de presión alta, baja e intermedia están descritas según una expansión unidimensional politrópica uniforme del vapor.
- Los volúmenes de energía almacenadas están agrupados.
- La energía cinética de ingreso del vapor para cada etapa es despreciable.
- Las dinámicas de flujo de masa entre la entrada y la salida se modelan como un modelo de primer orden.

II.3.2.3. Caldera

Las ecuaciones se obtienen de acuerdo a los siguientes supuestos:

- Se utiliza un grupo de modelos característicos concentrados en el que solo las derivadas temporales se consideran.
- Se utilizan aproximaciones de tablas de vapor para establecer la relación entre las variables tales como la entalpía, densidad y temperatura y presión del vapor.
- El vapor sobrecalentado y los gases de salida del horno se consideran como gas ideal.
- El flujo volumétrico del downcomer se mantiene constante para las bombas de recirculación.
- Las dinámicas de flujo para los elevadores y recalentadores se modelan como de 1er orden con retardo