

CENTRO DE INGENIERÍA Y DESARROLLO INDUSTRIAL

**IDENTIFICACIÓN Y CONTROL DE UN
MOTOR DIÉSEL SOBREALIMENTADO**

TESIS

QUE PARA OBTENER EL GRADO ACADÉMICO DE:

MAESTRO EN CIENCIA Y TECNOLOGÍA

EN LA OPCIÓN TERMINAL DE

MECATRÓNICA

PRESENTA:

ING. UBALDO JAVIER FLORA VELASCO

TUTOR ACADÉMICO:

DR. FERNANDO HERNÁNDEZ ROSALES



SANTIAGO DE QUERÉTARO, QUERÉTARO, DICIEMBRE 2014



Director de Posgrado
PICYT – CIDESI
Querétaro

Los abajo firmantes, miembros del Comité Tutorial del alumno **Ubaldo Javier Flora Velasco**, una vez leída y revisada la Tesis titulada **“Identificación y Control de un Motor Diésel Sobrealimentado”**, aceptamos que la referida tesis revisada y corregida sea presentada por el alumno para aspirar al grado de **Maestría en Ciencia y Tecnología** en la opción terminal de **Mecatrónica** durante el Examen de Grado correspondiente.

Y para que así conste firmo la presente a los 11 días del mes de Diciembre del año dos mil catorce.

Dr. Fernando Hernández Rosales

Tutor Académico



Director de Posgrado
PICYT – CIESI
Querétaro

Los abajo firmantes, miembros del Jurado del Examen de Grado de la alumno **Ubaldo Javier Flora Velasco**, una vez leída y revisada la Tesis titulada “**Identificación y Control de un Motor Diésel Sobrealimentado**”, aceptamos que la referida tesis revisada y corregida sea presentada por el alumno para aspirar al grado de **Maestría en Ciencia y Tecnología** en la opción terminal de Mecatrónica durante el Examen de Grado correspondiente.

Y para que así conste firmamos la presente a los 11 días del mes de Diciembre del año dos mil catorce.

M. C. Ricardo Chaparro Sánchez

Presidente

Dr. Eloy Edmundo Rodríguez Vázquez

Secretario

Dr. Fernando Hernández Rosales

Vocal

Contenido

Dedicatorias	viii
Lista de figuras	ix
Lista de tablas	xi
Glosario	xii
Resumen	xiv
CAPÍTULO I INTRODUCCIÓN	1
1.1 Antecedentes	2
1.2 Definición del tema	3
1.3 Justificación	4
1.4 Objetivos	9
1.5 Alcances y limitaciones.....	10
1.6 Estado del Arte	10
1.7 Organización de la tesis.....	13
CAPÍTULO II EL MOTOR DE COMBUSTIÓN INTERNA DIÉSEL.....	14
2.1 Funcionamiento del Motor de Combustión Interna Diésel	15
2.1.1 Motor de Combustión Interna Diésel de cuatro tiempos	17
2.2 Ciclo ideal Diésel.....	18
2.3 Análisis termodinámico del motor Diésel (Ciclo teórico Motor CI, 2010).....	19
2.4 Modelo del sistema de sobrealimentación + EGR de referencia desarrollado en Simulink de MATLAB por Salcedo et al. (Salcedo, J. V.; Martínez, M., 2007).....	21
2.4.1. El motor Diésel con Turbocompresor	21

2.4.2. Modelo en Simulink de Matlab	22
CAPÍTULO III MÉTODOS DE IDENTIFICACIÓN DE SISTEMAS	25
3.1. Introducción.....	26
3.1.1. Definición de sistema	26
3.1.2. Modelo de un sistema.....	26
3.1.3. Tipos de modelos	27
3.1.4. Métodos de obtención de modelos	28
3.2. Identificación de sistemas	29
3.2.1. El proceso de identificación	29
3.2.2. Métodos de identificación	30
3.3. Técnicas de identificación paramétrica	32
3.3.1. Tipos de modelos paramétricos	33
3.3.2. Métodos para el ajuste de parámetros	37
3.4. Identificación mediante Redes Neuronales	39
3.4.1. Introducción	39
3.4.2. Retropropagación	40
3.4.3. Algoritmos de Cálculo	42
3.4.4. Identificación de procesos dinámicos mediante redes neuronales	49
3.4.5. Señales y estrategias de entrenamiento	52
3.5. Consideraciones prácticas sobre identificación	54
3.5.1. Obtención de los datos	54
3.5.2. Pretratamiento de los datos	57
CAPÍTULO IV METODOLOGÍAS PARA EL DISEÑO DE CONTROLARES.....	58
4.1 Introducción.....	59
4.2 Sistemas Multivariables	60
4.3 Modelos de Sistemas Multivariables.....	60
4.3.1 Representación canónica P.....	61
4.3.2 Representación canónica V	62
4.3.3 Selección de tipo de estructura.....	62

4.3.4	Generación de la matriz de ganancias relativas.....	64
4.3.5	Selección de los lazos de control usando la Matriz de Ganancias Relativas.....	67
4.3.6	Técnicas de desacoplamiento de sistemas.....	69
4.4	Método de diseño analítico para sistemas en tiempo discreto	73
4.4.1	Diseño de controladores digitales para un tiempo de asentamiento mínimo con un error cero en estado permanente.....	73
4.5	Control Predictivo basado en Modelos (CPBM).....	80
4.5.1	Conceptos básicos del CPBM.....	81
4.5.1.1	Predictor.....	84
4.5.1.2	Función de costo.....	86
4.5.1.3	Optimizador.....	89
4.5.2	Algoritmos de control predictivo.....	90
CAPÍTULO V DESARROLLO Y RESULTADOS OBTENIDOS		93
5.1	Identificación paramétrica del sistema.....	94
5.1.1	Elección de las señales a medir.....	94
5.1.2	Elección de las entradas/salidas.....	95
5.1.3	Pretratamiento de los datos.....	96
5.1.4	Elección de la estructura del modelo.....	96
5.1.5	Validación del modelo.....	99
5.2	Modelo de identificación con Red Neuronal Artificial (RNA).....	100
5.2.1	Selección de las variables de entrada/salida.....	101
5.2.2	Preprocesamiento de datos.....	102
5.2.3	Elección de la arquitectura de la red.....	102
5.2.4	Procedimiento de iniciación y descripción del algoritmo de entrenamiento.....	104
5.3	Diseño y simulación del controlador PID.....	109
5.3.1	Desacoplamiento parcial del sistema.....	109
5.4	Diseño y simulación del sistema desacoplado completamente + controlador.....	111
5.4.1	Desacople del sistema.....	112
5.4.2	Diseño y simulación de controladores en tiempo discreto $G_D(z)$	112
5.5	Diseño y simulación de un Controlador Predictivo Basados en Modelos (CPBM).....	114
5.6	Validación de resultados.....	116

5.6.1 Validación de los modelos obtenidos.....	121
5.6.1.1 Validación del modelo multivariable identificado:	121
5.6.1.2 Validación de modelo RNA (figuras 5.12 a 5.16):.....	121
5.7 Publicaciones.....	122
CAPÍTULO VI CONCLUSIONES Y TRABAJO A FUTURO.....	123
6.1 Conclusiones.....	124
6.2 Fortalezas y debilidades	125
6.3 Trabajo a futuro	126
BIBLIOGRAFÍA	127
ANEXO 1 PUBLICACIONES	134
Anexo 1.1. Artículos	135
Anexo 1.2 Reconocimientos	140
ANEXO 2 PROGRAMAS.....	142
Anexo 2.1 Programa para Identificación del sistema.....	143
Anexo 2.2 Programa para entrenar la RNA.	144

Dedicatorias

“Te doy gracias, Yahveh, de todo corazón, cantaré todas tus maravillas.” Salmo 9,2.

A Dios por darme todo lo que soy, lo que tengo, lo que puedo.

“No es la carne y la sangre, sino el corazón, lo que nos hace padres e hijos.” Friedrich Schiller.

A mis padres, Alicia y Ubaldo, quienes con amor y confianza me dieron la educación más importante de mi vida.

“Una casa será fuerte e indestructible cuando esté sostenida por estas cuatro columnas: padre valiente, madre prudente, hijo obediente, hermano complaciente.” Confucio.

A Esther, Elena, Amparo, Jesús, Edith, Carmelita y Jenny por su amor fraterno y consideración infinita.

“Los niños son los dueños de la sonrisa, los grandes ya tenemos la sonrisa con cicatrices. Ellos tienen la sonrisa limpia, con ella van adelante y enseñan a reír de nuevo, a ser hombres y mujeres con alma de chicos”. Papa Francisco.

Muy especialmente a Luz, Gus, César, Montse, Júnior, Pepe, Lupita, Amparito, David, Jesús, Iván, Sebastián y Saúl, mis niños, quienes constituyen mi principal motivación.

“El amigo fiel no tiene precio, no hay peso que mida su valor.” Eclesiástico.

A mis amigos, quienes me apoyaron en todo momento con sus palabras de aliento e ideas. Ime, gracias por mostrarme el gran ser humano que eres.

**“Una educación verdadera debe suscitar la valentía de las decisiones definitivas”
Benedicto XVI.**

A mi tutor académico, el Dr. Fernando Hernández, y maestros que con sus enseñanzas y consejos contribuyeron en gran medida a este trabajo.

Lista de figuras

Figura 1. 1 Parque Vehicular a diésel, 2012-2027 (millones de vehículos) (SENER, 2013).....	4
Figura 1. 2 Precio de Gasolinas y Diésel en México, 1o. Noviembre de 2014.....	5
Figura 1. 3 Historial del estándar de emisiones para vehículos de carga	8
Figura 1. 4 Impacto del biodiésel en las emisiones de escape en vehículos de carga pesada. (EPA, 2002a)	9
Figura 1. 5 Estructura del modelo con SCR (Ericson, 2009; Juntadeandalucia, 2004).....	13
Figura 2. 1 Motor Diésel de cuatro tiempos	15
Figura 2. 2 Cilindro de un motor de combustión interna	16
Figura 2. 3 Ciclo de un motor Diésel de cuatro tiempos	18
Figura 2. 4 Ciclo termodinámico del motor Diésel	19
Figura 2. 5 Diagrama de un motor diésel con turbocompresor. Salcedo et al. (2001)	22
Figura 2. 6 Modelo del motor en Simulink. (Salcedo, J. V.; Martínez, M., 2007).....	24
Figura 3. 1 Sistema dinámico con entrada $u(t)$, perturbación $e(t)$ y salida $y(t)$	26
Figura 3. 2 Proceso de Identificación del Sistema.....	31
Figura 3. 3 Diagramas de bloques de las estructuras de la tabla 3.1.	36
Figura 3. 4 Red Neuronal Perceptrón Multi-capas.	40
Figura 3. 5 Red Neuronal simplificada.....	42
Figura 3. 6 Función Sigma o Sigmoide.	43
Figura 3. 7 Modelo de una red lineal de dos capas	50
Figura 3. 8 Modelo de un sistema dinámico no lineal.....	50
Figura 3. 9 Modelo de regresión generalizado.	52
Figura 3. 10 Entrada binaria aleatoria.	56
Figura 4. 1 Entrada escalonada aleatoria.	59
Figura 4. 2 Formas canónicas de sistemas multivariables (2x2)	61
Figura 4. 3 Conexión Feed-Forward en lazo de control simple.	70
Figura 4. 4 Conexión Feed-Forward compensado para desacoplar dos lazos.....	72

Figura 4. 5 Diagrama equivalente con desacoplador.....	73
Figura 4. 6 a) Un sistema de control digital. b) Diagrama de control equivalente.....	74
Figura 4. 7 Control Predictivo Basado en Modelos.	82
Figura 4. 8 Predicción de la salida y señal de control postulada.	83
Figura 4. 9 Estructura general de un modelo.....	85
Figura 5. 1 Sistema con dos entradas y dos salidas del Motor Diésel Sobrealimentado.....	95
Figura 5. 2 Comparación entre el modelo obtenido con Armax y los datos medidos.....	97
Figura 5. 3 Comparación entre el modelo obtenido con OE y los datos medidos.....	98
Figura 5. 4 Modelo Digital Multivariable, dos entradas y dos salidas	98
Figura 5. 5 Análisis de residuos del modelo EGR-ma	99
Figura 5. 6 Análisis de residuos del modelo TGV-ma	100
Figura 5. 7 Análisis de residuos del modelo EGR-Pa	100
Figura 5. 8 Análisis de residuos del modelo TGV-Pa	100
Figura 5. 9 Red Neuronal Perceptrón: 8 entradas, 1 capa oculta de 8 neuronas y 4 salidas ...	104
Figura 5. 10 Resultados del Programa en MatLab	105
Figura 5. 11 Resultados gráficos del entrenamiento (train), validación (validation) y prueba (test).....	106
Figura 5. 12 Gráfica de Resultados	106
Figura 5. 13 Regresión lineal del entrenamiento.....	107
Figura 5. 14 Regresión lineal de la validación	107
Figura 5. 15 Regresión lineal de la prueba	108
Figura 5. 16 Regresión lineal promedio	108
Figura 5. 17 Sistema desacoplado, controlado por un PID.....	110
Figura 5. 18 Presión del aire, Pa, controlada por un PID	111
Figura 5. 19 Masa del aire, ma, controlada por un PID.....	111
Figura 5. 20 Sistema con controladores en tiempo discreto	113
Figura 5. 21 Presión del aire, Pa, controlada por controlador en tiempo discreto.....	113
Figura 5. 22 Masa del aire, ma, controlada por controlador en tiempo discreto	114
Figura 5. 23 CPBM para controlar Pa y ma de un motor de combustión interna diésel	115
Figura 5. 24 Presión del aire, Pa, controlada por un CPBM.....	115

Figura 5. 25 Masa del aire, ma, controlada por un CPBM.....	116
Figura 5. 26 Simulación del controlador PI para el control de la presión del aire, Pa. (Salcedo, Blasco, Martínez, & García, 2001).....	117
Figura 5. 27 Simulación del controlador PI para el control de la masa del aire, ma. (Salcedo, Blasco, Martínez, & García, 2001).....	117
Figura 5. 28 Simulación del MPC para el control de la presión del aire, Pa.....	118
Figura 5. 29 Simulación del MPC para el control de la masa del aire, ma.	119
Figura 5. 30 Simulación del MPC para el control de la presión del aire, Pa. Acercamiento. .	119
Figura 5. 31 Simulación del MPC para el control de la masa del aire, ma. Acercamiento.	120

Lista de tablas

Tabla 1. 1 Historial del estándar de emisiones para vehículos de carga. g/bhp-hr.....	7
Tabla 3. 1 Diversas estructuras de modelos paramétricos.....	35
Tabla 4. 1 Principales índices de funcionamiento.	87
Tabla 5. 1 Variables respuesta del motor de combustión interna Diésel a predecir con RNA	101
Tabla 5. 2 Variables del motor de combustión interna Diésel que tienen influencia tanto en las emisiones como en el consumo y en la temperatura de escape (Hernández López, 2006)	102
Tabla 5. 3 Datos de simulación de la RNA	109

Glosario

PM: Partículas (Particulate Matter)

EPA: U. S. Environmental Protection Agency

Gas de Carbón: (Coal Gas) Gas de hulla, gas preparado por destilación de carbón bituminoso en retortas, usado para alumbrado y calefacción (García, 2005)

TDC: Punto muerto superior (Top Dead Center)

BDC: Punto muerto inferior (Bottom Dead Center)

TGV: Turbina de Geometría Variable (Variable Turbine Geometry)

EGR: Gases de Escape Recirculados (Exhaust Gas Recirculation)

HC: Hidrocarburos sin quemar (Hydrocarbons)

g/bhp-hr gramos/hp reales- hr (grams per brake horsepower-hour)

NOx: Óxidos de Nitrógeno, NO y NO₂ (oxides of nitrogen)

Biodiésel: Fatty-Acid Methyl Ester (FAME) es un término genérico aplicado a aceites vegetales o animales los cuales han sido transesterificados con metanol. FAME es producido de varios elementos crudos, principalmente de semillas de soya, de girasol, ésteres de palma, ésteres de sebo de res, pero éstos son comúnmente usados en conjunto con otros FME (Fat Methyl Ester).

Transesterificación: El biodiésel se obtiene del prensado de semillas oleaginosas de colza, soya o girasol, a partir de una reacción denominada transesterificación, que determina la sustitución de los componentes alcohólicos de origen (glicerol) por alcohol metílico (metanol).

Colza: Especie de col de flores amarillas y semillas oleaginosas

Ester: Quím. Cuerpo derivado de la acción de un ácido sobre un alcohol.

λ Factor de exceso de aire: $\lambda = \text{masa aire} / \text{masa combustible}$. Razón estequiométrica. La razón estequiométrica indica la masa de aire en Kg requerida para quemar completamente 1Kg de combustible (mL/mK). Para motores diésel esto es aproximadamente 14.5. Pag.64 (Bosch GmbH, 2005).

Ancho de banda: Para señales analógicas, es la longitud, medida en hercios (Hz), del rango de frecuencias en el que se concentra la mayor parte de la potencia de la señal. Puede ser calculado a partir de una señal temporal mediante el análisis de Fourier. También son llamadas frecuencias efectivas las pertenecientes a este rango.

Contaminante: Se denomina contaminante a toda aquella sustancia natural o artificial que introducida en concentración suficiente en el medio ambiente puede producir un efecto medible sobre los seres humanos, animales, vegetales o materiales de construcción” (Bacha, et al., 1998).

Resumen

Este trabajo constituye una propuesta para optimizar el funcionamiento de los motores de combustión interna a Diésel ampliamente utilizados en los vehículos de carga y transporte de pasajeros. Además, en años recientes se ha visto el interés de algunos fabricantes por introducir al mercado vehículos compactos, tal como la han llevado a cabo las marcas Volkswagen, Peugeot, Mercedes Benz, BMW, Seat, Fiat, entre otros. A nivel nacional se encuentran disponibles algunos modelos: Volkswagen: Jetta y Vento; Peugeot: Partner Tepee; Audi: A4 y Q3.

Se ha obtenido un modelo multivariable discreto de un motor de combustión interna diésel sobrealimentado, utilizando métodos de identificación aplicados a un modelo matemático completo de un motor diésel sobrealimentado desarrollado en Simulink de MATLAB. Debido al fuerte acoplamiento existente entre las variables de entrada y salida se llevó a cabo una metodología de desacoplamiento de sistemas multivariables. Una vez desacoplado dicho sistema, se desarrollaron controladores para este modelo, un controlador PID, un controlador discreto y un Controlador Predictivo Basado en Modelos (CPBM). Las variables que se controlaron fueron la presión en el colector de admisión (P_a) y el gasto másico del aire (m_a). A través de dichos controladores se logró un control de las variables P_a y m_a , manipulando oportunamente los elementos finales de control: la válvula del flujo hacia la Turbina de Geometría Variable (TGV) y la válvula del flujo de Recirculación de los Gases de Escape (EGR). Esto permitirá seguir el registro óptimo de las variables controladas, según las cartas de comportamiento de variables de los fabricantes, consiguiendo consecuentemente, una mejora en el rendimiento y disminución de contaminantes del Motor Diésel.

CAPÍTULO I

INTRODUCCIÓN

1.1 Antecedentes

En los últimos años ha ido en aumento, a nivel mundial, la preocupación sobre los temas relacionados con el calentamiento global, calidad del aire en las ciudades, lluvias ácidas y efecto invernadero, y desde luego sus repercusiones en la salud de la población y medio ambiente.

Por otro lado, el gran incremento poblacional ha traído consigo el acelerado crecimiento de la industria para satisfacer sus demandas, ocasionando un aumento considerable en la fabricación de vehículos que consumen derivados del petróleo, tanto de carga ligera como pesada. El impacto al medio ambiente ha sido también muy grande, debido a la emisión de contaminantes de la atmósfera, tales como CO, CO₂, NO_x (NO y NO₂), HC, partículas (PM). Los vehículos automotores juegan un papel importante en este proceso por la cantidad de ellos que circulan diariamente.

La Secretaría de Medio Ambiente y Recursos Naturales ha publicado a través del diario oficial (10 de febrero de 2003) que podrán importarse los vehículos automotores equipados con motores Diésel siempre y cuando ostenten las especificaciones contenidas en las Normas de la Agencia de Protección Ambiental de los Estados Unidos de América, denominadas EPA 1998 y EPA 2004 o en las Normas Europeas denominadas Euro III y Euro IV (Semarnat, 2003).

La EPA ha proporcionado estándares actualizados para vehículos diésel de carga pesada. Los parámetros de emisión permitidos del 2010 en adelante (g/bhp-hr): HC:0.14, CO:15.50, NO_x: 0.20, PM:0.01. (EPA, 2002).

Cada vez es más difícil por parte de los fabricantes de vehículos cumplir con las restricciones marcadas por las autoridades ambientales, por lo que día con día utilizan la tecnología de vanguardia para obtener modelos más exactos de los motores de combustión interna que les permitan optimizarlo.

1.2 Definición del tema

Actualmente los usuarios de vehículos automotores demandan sistemas más eficientes, que entreguen altas potencias, ahorro en el consumo de combustible y menores tiempos de respuesta; en contraposición tenemos las leyes ambientales que limitan cada vez más la emisión de contaminantes a la atmósfera, tales como: Partículas: Humos + Hidrocarburos y óxidos de nitrógeno. Los Motores de Combustión Interna Diésel sobrealimentados, es decir, con sistema turbocompresor, se presentan como una buena alternativa, ya que estos motores ofrecen un mejor rendimiento y una mayor potencia que los motores diésel atmosféricos, gracias a que la turbocompresión faculta el manejo de presiones y temperaturas más elevadas dentro de las cámaras de combustión. Efectivamente los motores de este tipo tienen un aumento considerable en la potencia y una reducción en el consumo específico de combustible, sin embargo, el incremento en la presión y temperatura favorece la producción de óxidos de nitrógeno (NO_x) en los gases de escape.

Las normas actuales en cuanto a la emisión de NO_x son muy estrictas. Ante esta situación, una alternativa por la que se ha optado es la recirculación de los gases, producto de la combustión, desde el escape al colector de admisión, propiciando la disminución de la temperatura. Sin embargo, esta estrategia tiene el inconveniente de que disminuye de forma significativa las prestaciones del motor, de ahí que el control de este sistema sea de gran importancia.

Una manera de contrarrestar la pérdida de potencia o par del motor consiste en modificar la apertura de la Turbina de Geometría Variable (TGV) del turbosistema, haciendo que la presión de los gases en el colector de escape se regule y, consecuentemente, se consiga variar la potencia mecánica de la TGV, que a su vez controlará la presión de sobrealimentación. Este control permitirá tener mayores gastos másicos de aire, \dot{m}_a .

La producción de partículas se debe principalmente a problemas relacionados con el dosado alto ($\lambda = A/F$, para motores sobrealimentados debe estar entre 1.15 y 2). Por lo tanto, si se suministra el suficiente aire fresco (\dot{m}_a), se contribuirá a la disminución de su formación, y mayores cantidades de aire permitirán incrementar el flujo de combustible y, en consecuencia, un mayor torque.

La formación de NOx se da por la reacción entre el oxígeno y el nitrógeno en condiciones de alta temperatura. Si la combustión se produce en presencia de compuestos inertes de alto calor específico, tal como los gases de escape (EGR), se puede limitar la formación de NOx. (Salcedo, 2007).

1.3 Justificación

La creciente cantidad de vehículos automotores que se suman día con día al ya gran parque vehicular, nos motivan a buscar alternativas para disminuir los problemas derivados de este fenómeno.

El número de vehículos con motor a diésel en México era de 811.4 mil unidades en el 2012 y se prevé que durante el periodo 2012-2027 el parque vehicular de diésel presente un ritmo de crecimiento de 5.1% (tasa media de crecimiento anual, tmca), es decir, la cantidad de automotores a diésel será de 1.7 millones de unidades al final del periodo. La participación de estos vehículos respecto al parque vehicular total por tipo de combustible será de 3.5%.

Un proyecto prioritario para PEMEX Refinación es el de Calidad de combustibles. Entre 2013 y 2027, 9.8% de la inversión se destinará a este proyecto. La Fase gasolinas, que iniciará operaciones a partir de 2014, tiene como objetivo homologar, con respecto a estándares internacionales, la calidad de la gasolina producida a nivel nacional. Por su parte, el objetivo de la Fase diésel es producir diésel de 15 partes por millón (ppm) máximo de azufre en peso. El proyecto de producción de diésel UBA (Ultra Bajo Azufre) está ya iniciado, al finalizar 2012 se encontraban en proceso la Ingeniería, Procura y Construcción (IPC) en las seis refinerías, el inicio de operación se hará durante el periodo 2015-2027.

Región	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024	2025	2026	2027	tmca
Total	0.8	0.8	0.9	0.9	1.0	1.1	1.1	1.2	1.2	1.3	1.4	1.4	1.5	1.6	1.6	1.7	5.1
Noroeste	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.09	0.10	0.10	0.11	0.12	0.12	0.13	0.13	0.14	3.3
Noreste	0.20	0.22	0.23	0.24	0.25	0.27	0.28	0.30	0.31	0.32	0.34	0.35	0.37	0.38	0.40	0.42	4.9
Centro-Occidente	0.18	0.19	0.20	0.22	0.23	0.25	0.27	0.28	0.30	0.31	0.33	0.35	0.36	0.38	0.40	0.42	5.8
Centro	0.23	0.24	0.26	0.28	0.30	0.32	0.34	0.36	0.38	0.39	0.41	0.43	0.45	0.47	0.49	0.51	5.4
Sur-Sureste	0.11	0.11	0.12	0.12	0.13	0.14	0.14	0.15	0.16	0.17	0.18	0.19	0.20	0.21	0.21	0.22	4.7

Fuente: Elaborado por IMP, con base en AMDA, AMIA, ANPACT, BANXICO, CONUEE, CRE, EIA, EPA, INEGI, PEMEX, SENER y empresas privadas.

Figura 1. 1 Parque Vehicular a diésel, 2012-2027 (millones de vehículos) (SENER, 2013)

Un factor importante a considerar en la región de Norteamérica es la transición hacia un parque vehicular más eficiente. En este sentido la evolución tecnológica de los motores a diésel ha modificado el modo de operación de las refinerías de la costa norteamericana del Golfo de México, ya que anteriormente enfocaron sus procesos en la producción de gasolina y hoy se ha sustituido por la elaboración de diésel, al considerar su mayor crecimiento relativo. (SENER, 2013).

Por otro lado, tenemos el incremento en los precios de los combustibles fósiles establecidos por la Secretaría de Hacienda y crédito Público (SHCP) de manera mensual. Es un aspecto a tomar en cuenta para optimizar el consumo y uso de los combustibles, a partir del 1o. de Noviembre de 2014 la gasolina Magna se incrementó 9 centavos y la gasolina Premium, y el diésel subió 11 centavos por cada litro. Ver figura 1.2.

PRODUCTO	ANTES	SUBE	HOY
Magna	13.13	\$ 0.09	13.22
Premium	13.89	\$ 0.11	14.00
Diesel	13.72	\$ 0.11	13.83

Figura 1. 2 Precio de Gasolinas y Diésel en México, 1o. Noviembre de 2014.

En seguida se comentan brevemente algunos fenómenos en los que participan las emisiones producidas por los motores Diésel:

a) Cambio climático. “Se denomina cambio climático a las fluctuaciones dentro de una larga escala temporal de temperaturas, precipitaciones, viento y otros elementos del clima del planeta”. Este fenómeno está producido por un aumento en la concentración de gases atmosféricos que afectan a la absorción de la energía de radiación terrestre. Los compuestos a los que se debe el efecto invernadero a nivel estratosférico son CO₂, metano, N₂O, o compuestos halogenados que contienen flúor, cloro o bromo (como CFC, HCFC, etc). A nivel troposférico también hay determinados compuestos que modifican el balance radiactivo terrestre como CO, NO₂, SO₂ y O₃. ((EPA) U. S., 2002).

b) SMOG fotoquímico. Es un tipo de polución del aire a nivel troposférico en las áreas metropolitanas, en forma de neblina y con elementos oxidantes como el ozono. La troposfera comprende la capa atmosférica más próxima a la superficie terrestre, hasta una altura entre 12 y 15 Km. A estos niveles, el ozono se forma por la interacción de compuestos orgánicos volátiles y de NOx con la radiación solar ultravioleta. “El ozono daña tejidos pulmonares, reduce la función pulmonar y expone al pulmón a otros elementos irritantes. Es responsable cada año de pérdidas de cosechas por valor de varios billones de dólares en USA y causa daños notables en las hojas de muchas cosechas y especies de árboles” (Agency, 1993).

c) Lluvia ácida. Se denomina lluvia ácida a todo tipo de precipitación (lluvia, nieve o niebla) cuyo pH esté por debajo de 5, que es el nivel natural. Ciertos compuestos, como SO₂ y NO₂, reaccionan con el vapor de agua de la atmósfera produciendo ácido sulfúrico y ácido nítrico, que son responsables de la acidificación de las precipitaciones. Los efectos de la lluvia ácida se extienden tanto a la salud humana (causando trastornos en las vías respiratorias), como a las construcciones (acelerando el deterioro de los edificios) (Hernández López, 2006).

d) Disminución de la capa de ozono. Por encima de la estratósfera se sitúa una fina capa de ozono. A estos niveles, el ozono absorbe la mayor parte de la radiación ultravioleta del sol, evitando que esta radiación de alto contenido energético (relacionada por ejemplo con los cánceres de piel) alcance el nivel troposférico. Si las emisiones de N₂O no son disueltas por el agua, alcanzan la estratósfera y contribuyen a la reducción de la capa de ozono. (Hernández López, 2006).

Como es de esperar, las organizaciones no solo a nivel local sino internacional han generado toda una normatividad para restringir la emisión de contaminantes en vehículos que utilicen combustibles fósiles.

La Secretaria de Medio Ambiente y Recursos Naturales publicó el 10 de febrero de 2003 en el Diario Oficial un acuerdo, en el cual se dan a conocer criterios de carácter ambiental para la importación definitiva a la República Mexicana de Vehículos automotores nuevos, equipados con motor diésel. Este acuerdo dice en su artículo único que los vehículos automotores nuevos

equipados con motor a diésel con peso bruto vehicular mayor a 3,857 kilogramos, así como los motores para los citados vehículos, podrán importarse de forma definitiva siempre y cuando ostenten las especificaciones contenidas en las Normas de la Agencia de Protección Ambiental de los Estados Unidos de América, denominadas EPA 1998 y EPA 2004 o en las Normas Europeas denominadas Euro III y Euro IV.

La Agencia de Protección Ambiental de los Estados Unidos de América se creó hace tres décadas para proteger la salud humana y salvaguardar el medio ambiente. La EPA ha provisto de estándares para vehículos diésel de carga pesada. En la tabla 1 se presenta un resumen de los estándares de emisiones emitidos por la EPA para vehículos nuevos diésel de carga pesada, desde 1988 hasta 2010.

La emisión estándar de PM mencionada en la tabla 1 debe ser cumplida por los todos los vehículos diésel de carga pesada, modelo 2007 y modelos posteriores. Sin embargo, los estándares de NOx y HC son proyectados para ser cumplidos entre 2007 y 2010. Esta proyección es basada en el porcentaje total de vehículos vendidos, 50% de estos vehículos deberá cumplir con el requerimiento de la norma del 2007 al 2009, llegando al 100% en el 2010 ((EPA) A. E., 2000).

Tabla 1. 1 Historial del estándar de emisiones para vehículos de carga. g/bhp-hr (EPA, 2000)

AÑO	HC	CO	NOx	PM
1988	1.30	15.50	10.70	0.60
1990	1.30	15.50	6.00	0.60
1991	1.30	15.50	5.00	0.25
1994	1.30	15.50	5.00	0.10
1998	1.30	15.50	4.00	0.10
2004	0.50	15.50	4.00	0.10
2007-2010	0.14	15.50	0.20	0.01

Durante la década pasada la industria automotriz ha invertido enormes cantidades en el desarrollo y la creación de motores Diésel más limpios. Los avances han sido forzados por la

legislación tan estricta en lo que se refiere a emisiones, por parte, tanto de las autoridades Europeas como Americanas. En los 90's, los niveles de emisión de la Euro III fueron solventados utilizando más altas presiones en el sistema de inyección para disminuir la emisión de partículas, y retardando la inyección se bajaron los niveles de NOx. Superar los requerimientos de la Euro IV significó muchas dificultades para la tecnología tradicional. Algunos fabricantes introdujeron el enfriamiento de los gases EGR para disminuir los NOx, otros utilizaron la Reducción Catalítica Selectiva (SCR) con urea/AdBlue como agentes de reducción. Usando SCR, los tiempos de inyección se enfocaron en la economía del combustible. Los motores que han logrado superar los requerimientos de emisiones de la Euro V muestran el uso, ya sea, de la tecnología EGR o SCR. (Ericson, 2009).

El estándar de la Euro VI está aún por determinarse; una suposición razonable es que los niveles de emisión estarán alrededor de 0.5 g/kWh NOx y 10 mg/kWh PM. Tales niveles de emisión requerirán tecnologías más avanzadas y mucho trabajo de optimización. Los Hidrocarburos (HC) y monóxido de carbono (CO) son también regulados, no obstante, estos niveles de emisión no representan tantas dificultades para los motores Diésel debido a las altas relaciones de aire-combustible.

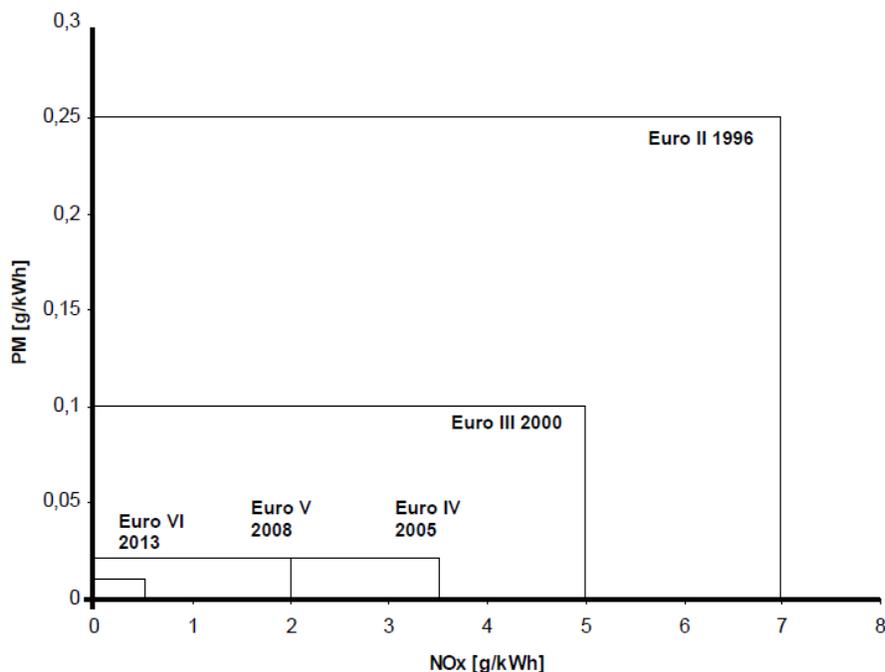


Figura 1. 3 Historial del estándar de emisiones para vehículos de carga

Los motores a diésel son de actualidad debido al creciente interés en el uso de biodiésel como sustituto del diésel, en respuesta, la EPA ha dirigido varios estudios cuyo objetivo es determinar el verdadero efecto que tiene el biodiésel en el medio ambiente cuando es utilizado como combustible en los motores de combustión interna. Cabe mencionar que la manera más frecuente de utilización del biocombustible es en una mezcla a diferentes proporciones de diésel y biodiésel. Se realizó el análisis de emisiones de gases de escape en un motor de combustión interna a diésel, se hizo la comparación entre dos tipos de combustible: el diésel al 100% y la mezcla con 80% de diésel y 20% de biodiésel (extraído de semillas de soya), y se obtuvieron los siguientes resultados: PM: -10.1%, HC: -21.1%, CO: -11.0% y NOx: +2.0%. Como se puede constatar, se registró una disminución en la mayoría de los gases de emisión, excepto en los óxidos de nitrógeno. Ver figura 1.4 para más detalles.

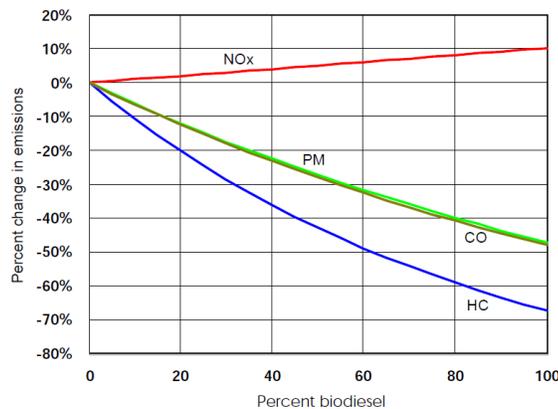


Figura 1. 4 Impacto del biodiésel en las emisiones de escape en vehículos de carga pesada. (EPA, 2002a)

1.4 Objetivos

Obtener un modelo paramétrico de un motor de combustión interna Diésel sobrealimentado que pueda representar eficientemente el funcionamiento real de un motor de este tipo.

Modelar un motor de combustión interna Diésel utilizando Redes Neuronales Artificiales para predecir la emisión de contaminantes.

Diseñar un controlador que permita optimizar el comportamiento de la presión del aire en el colector de admisión (P_a) y el gasto másico del aire (\dot{m}_a) en un motor de combustión interna Diésel sobrealimentado, según lo requieran las cartas de fabricación.

1.5 Alcances y limitaciones

Los motores de combustión interna son sistemas de múltiples variables, las cuales se seleccionan dependiendo los objetivos que se pretendan alcanzar. Esta investigación tiene contemplado realizar el estudio y análisis para desarrollar un modelo multivariable y discreto para dos entradas y dos salidas, teniendo como variables de entrada la posición de la válvula que regula el flujo hacia la turbina de geometría variable (TGV) y la apertura de la válvula del flujo de recirculación de los gases de escape (EGR) y como variables de salida, la presión del aire en el colector de admisión (P_a) y el gasto másico del aire (\dot{m}_a). Se utilizará como base de la experimentación durante la investigación, un modelo aproximado de un motor de combustión interna Diésel Sobrealimentado desarrollado en Matlab por los científicos J. V. Salcedo y M. Martínez (2001) de la universidad Politécnica de Valencia. Esta propuesta no contempla la implementación de los controladores desarrollados.

1.6 Estado del Arte

A continuación se presenta una revisión de algunas publicaciones relacionadas con el tema de estudio de este trabajo.

Se previene la contaminación del aire causada por la emisión de partículas en embarcaciones marítimas. Se demuestra que el 64% del consumo de aceite contribuye en el total de las partículas formadas, por lo que se propone la necesidad de modificar el diseño de los anillos del pistón a unos de bajo consumo para disminuir el nivel de contaminantes (Miller, Jackson, Brown, & Wong, 1998).

Michael L. Traver y compañía, logran predecir la cantidad de gases de escape NOx y CO2 en línea mediante el monitoreo de parámetros derivados de la combustión, así como la presión interna en los cilindros. Haciendo uso de la estadística se analizaron los datos obtenidos y se determinaron las variables más representativas y con más contribución en las variables de salida. Dichas variables se consideraron como entradas de una red neuronal, cuyas salidas fueron HC, CO, CO2 y NOx. Finalmente este sistema se implementó en un DSP (Digital Signal Processor) logrando la predicción en línea de los gases de escape (Traver, Atkinson, & M., 1999).

Técnicas de lógica difusa y Neuro-Fuzzy fueron empleadas por Lee et al. (Lee, Howlett, Walters, & Crua, 2001) para modelar el comportamiento de la atomización del diésel y así mejorar la mezcla de aire-combustible con la consecuente disminución de emisiones contaminantes. Se utilizó la medición de presión en el cilindro, la densidad del aire y temperatura como entradas principales, y la longitud de penetración como la salida. El modelo describió al proceso en un 99.7%.

Considerando también el trabajo de Agrawal et al (Agrawal, Singh, Sinha, & Shukla, 2004), la EGR (Recirculación de los gases de escape) se presenta como una alternativa para disminuir las emisiones contaminantes. En los motores diésel la formación de NOx está fuertemente relacionada la temperatura de la cámara de combustión, sobre todo cuando la temperatura rebasa los 2000 K. El EGR causa un incremento en el retardo de la ignición, incrementa el calor específico de la materia no reaccionante presente en la combustión disminuyendo la temperatura de la misma. Se concluye que el EGR de 0-21% favorece el decremento de la temperatura de los gases de escape con la consecuente disminución de NOx.

Salcedo et. al (Salcedo, J. V.; Martínez, M., 2007) desarrollaron un modelo lineal multivariable de un motor diésel sobrealimentado y con EGR. Aplicando métodos de identificación de sistemas y tomando como base el modelo descrito en el punto 2.4, donde se toman como entradas la apertura de las válvulas TGV y EGR, y como salidas Pa (Presión en el colector de admisión) y ma (Gasto másico entregado por el compresor), se obtiene un modelo continuo y multivariable:

$$G_p(s) = \begin{bmatrix} \frac{-379(1.15s + 1)}{(0.75s + 1)(0.17s + 1)} & \frac{-25.7(-20s + 1)}{(s + 1)(0.1s + 1)} \\ \frac{6.5 \cdot 10^{-4}}{(0.2s + 1)} & \frac{-9.1 \cdot 10^{-4}}{(0.2235s + 1)} \end{bmatrix} \quad 1.1$$

Es un modelo sencillo donde las funciones de transferencia son de primero y segundo orden. A partir de este modelo diseñaron dos controladores PI independientes los cuales permiten controlar la apertura de las válvulas de control de EGR y TGV. Por medio de implementaciones sencillas lograron un control con un buen comportamiento.

J Wahlström et. al (2011) desarrollaron, parametrizaron y validaron el modelo de un motor diésel sobrealimentado con turbina de geometría variable (VGT) y recirculación de gases de escape (EGR). Dicho modelo se desarrolló en Simulink de Matlab y los parámetros fueron estimados utilizando técnicas de optimización de mínimos cuadrados. La validación del modelo presentó un error medio del 5.8 por ciento en las variables medidas.

J W Mann (2011) realizó un análisis del desempeño de un motor diésel con turboalimentación dual en aplicación submarina, comparándolo con otros tipos. Encontró que el motor turboalimentado presentaba mayores variaciones en su desempeño con un consumo específico de combustible marginalmente mejor que un motor superalimentado aunque, este último, más estable a las variaciones de entrada. El motor con doble turboalimentación fue menos estable que el de turboalimentación simple, pero ofreció un mejor consumo de combustible, mayor torque y potencia, aunque mayor inestabilidad en la velocidad. (Mann, 2011).

Claes Ericson (2009) considerando el motor y los sistemas de post-tratamiento como una sola unidad para conseguir un buen balance entre la regulación de emisiones y consumo CO₂/combustible, diseña un sistema con un modelo casi estable de intercambio de gas y un modelo de combustión no analítico, ver fig. 1.5. De acuerdo con las mediciones realizadas obtuvo una predicción con un error relativo de -8.5% y la conversión catalítica de NOx con el SCR (Reducción Catalítica Selectiva) tuvo un error del 4.0% (Ericson, 2009).

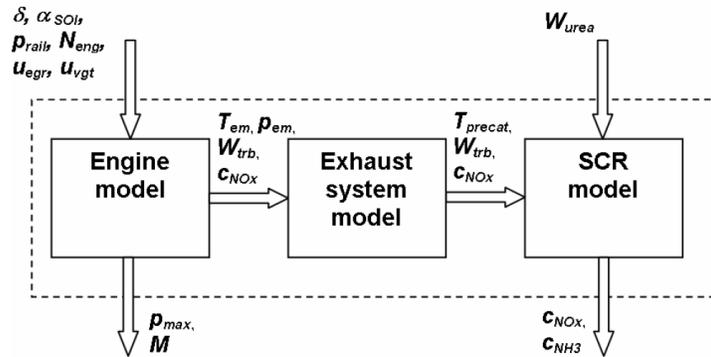


Figura 1. 5 Estructura del modelo con SCR (Ericson, 2009; Juntadeandalucia, 2004)

1.7 Organización de la tesis

En el capítulo II se presentan los conceptos básicos relacionados con el funcionamiento de un motor de combustión interna Diésel. También se presenta un análisis de la termodinámica de este tipo de motores y por último se expone el cálculo de la eficiencia.

En el capítulo III se mencionan los conceptos básicos y algunas metodologías para la identificación de sistemas, tal como tipos de modelos, métodos de identificación y algunas técnicas de identificación paramétrica. Por último se dan los conceptos básicos para identificar sistemas mediante redes neuronales.

En el capítulo IV se presentan conceptos básicos relacionados con controladores multivariables, tales como el desacoplamiento de sistemas y algunos métodos de diseño de sistemas de control en tiempo discreto y del Controlador Predictivo Basado en Modelo (CPBM).

En el capítulo V se describe el desarrollo y procedimientos aplicados en los modelos y propuestas que forman parte de este trabajo, así como los resultados obtenidos y la validación de los mismos.

En el capítulo VI se presentan las conclusiones de esta investigación, se mencionan las fortalezas y debilidades, y el trabajo a futuro derivado de esta propuesta.

CAPÍTULO II
EL MOTOR DE
COMBUSTIÓN INTERNA
DIÉSEL

2.1 Funcionamiento del Motor de Combustión Interna Diésel

Rudolff Diésel fue un ingeniero alemán que, a finales del siglo XIX, diseñó el motor que lleva su nombre. En términos mecánicos, la construcción interna de un motor Diésel es similar a su contraparte de gasolina – componentes como pistones, bielas y un cigüeñal están presentes en ambos (ver figura 2.1). Así como un motor de gasolina, un motor Diésel puede operar en un ciclo de cuatro tiempos (similar al ciclo Otto de las unidades de gasolina), o a un ciclo de dos tiempos, aunque con significativas diferencias. En ambos casos, la principal diferencia yace en el manejo de aire y combustible y el método de ignición (Hooley's).

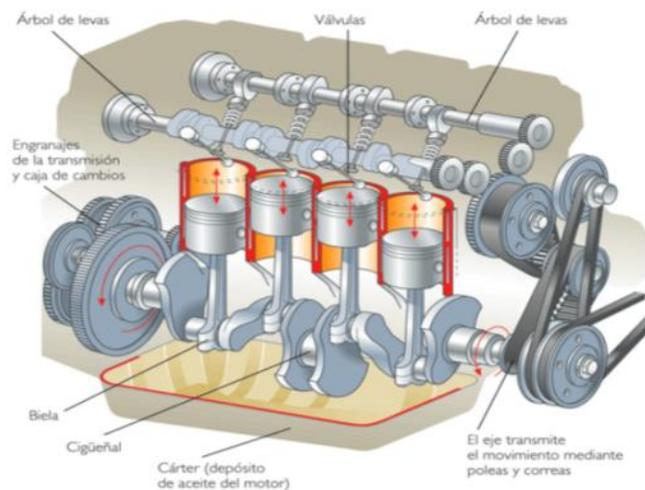


Figura 2. 1 Motor Diésel de cuatro tiempos

Un motor Diésel utiliza la compresión como ignición para quemar su combustible, en lugar de la chispa de la bujía en un motor de gasolina. Si el aire es comprimido a un alto nivel, su temperatura se incrementará a un punto tal que el combustible se quemará cuando entren en contacto. Este principio es usado por el motor Diésel de dos y cuatro tiempos para generar energía mecánica.

A diferencia de un motor de gasolina, al cual se le alimenta una mezcla de aire/combustible al cilindro durante la etapa de admisión, el motor Diésel aspira aire solamente. Enseguida de la admisión el cilindro es sellado y la carga de aire se comprime a altas presiones para calentarlo a la temperatura requerida para la ignición. Mientras en un motor de gasolina la relación de

compresión raramente es mayor de 11:1 para evitar perjudicar la preignición, una relación de compresión del Diésel es usualmente entre 16:1 y 25:1. Este nivel extremadamente alto de compresión ocasiona que la temperatura del aire se incremente un intervalo de 700 a 900 grados Celsius (1300 a 1650 grados Fahrenheit). Si un pedazo de acero fuera calentado a esa temperatura tomaría un rojo cereza fulgurante.

Cuando el pistón se aproxima al Punto Muerto Superior (P.M.S.), el combustible es inyectado al cilindro a alta presión, ocasionando que el combustible sea atomizado. A causa de la alta temperatura del aire dentro del cilindro, la ignición ocurre instantáneamente, causando un rápido y considerable incremento en la temperatura y presión en el cilindro. El pistón es impulsado hacia abajo con gran fuerza, empujando la biela y girando el cigüeñal.

Cuando el pistón está cerca de Punto Muerto Inferior (P.M.I.) los gases generados son expulsados desde el cilindro para el próximo ciclo. En muchos casos, los gases de escape serán usados para manejar una turbina de alimentación, la cual incrementa el volumen de la carga de aire en la admisión, resultando en una combustión más limpia y eficiente (Obert, 1982).

La secuencia de arriba generalmente describe cómo opera el motor Diésel.

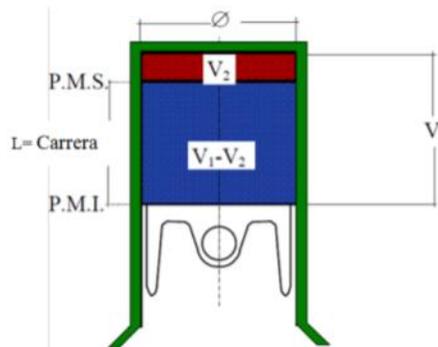


Figura 2. 2 Cilindro de un motor de combustión interna

2.1.1 Motor de Combustión Interna Diésel de cuatro tiempos

El ciclo comienza con la etapa de admisión (Fig. 2.3 A), la cual empieza cuando el pistón está en el punto muerto superior. La válvula de admisión es abierta, permitiendo el paso desde el exterior del motor (generalmente a través de un filtro de aire) hasta el puerto de admisión en la cabeza del cilindro y al cilindro mismo. Cuando el pistón va hacia el punto muerto inferior, se desarrolla un vacío parcial, causando que el aire entre al cilindro. En el caso de un motor con turbocompresor, el aire es compactado dentro del cilindro a presiones más altas que la atmosférica. Cuando el pistón pasa por el punto muerto inferior, la válvula de admisión cierra, sellando el cilindro.

La etapa de compresión (Fig. 2.3 B) empieza cuando el pistón está en el punto muerto inferior y comienza a subir. La compresión continuará hasta que el pistón se aproxime al punto muerto superior.

La etapa de potencia (Fig. 2.3 C) ocurre cuando el pistón alcanza el punto muerto superior al final de la etapa de compresión. En este tiempo, la inyección de combustible ocurre, resultando la combustión y la producción de trabajo útil.

El paso final es la etapa de escape (Fig. 2.3 D), la cual empieza cuando el pistón se aproxima al punto muerto inferior después de la ignición. La válvula de escape en la cabeza del cilindro es abierta y, cuando el pistón empieza a subir, los gases generados en la combustión son forzados a salir del cilindro. Cerca de punto muerto superior la válvula de admisión empezará a abrir antes de que la válvula de escape esté completamente cerrada, una condición conocida como válvula superpuesta. La superposición produce un flujo refrigerante de aire admitido sobre la válvula de escape, prolongando su vida. Una vez completada la etapa de escape, el ciclo vuelve a empezar nuevamente.

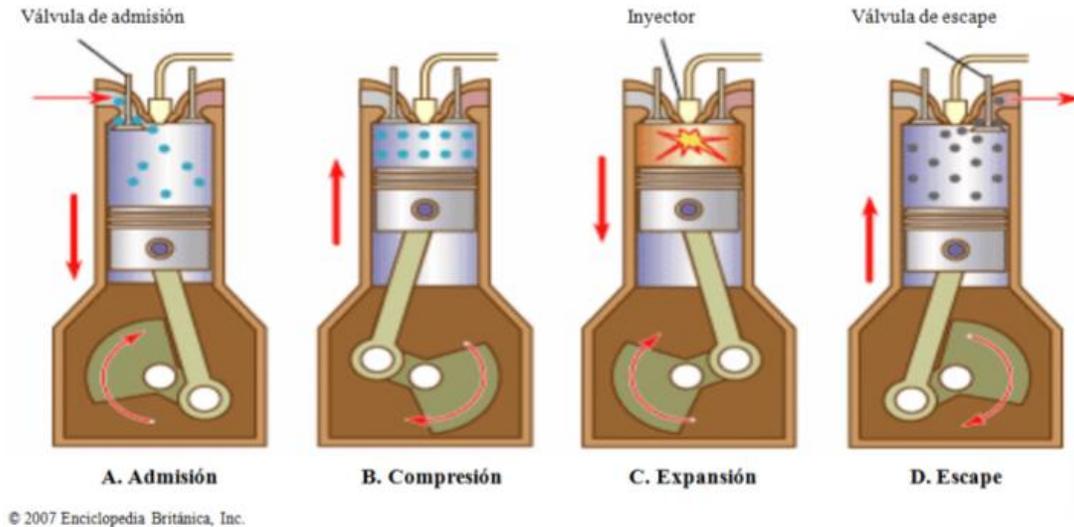


Figura 2. 3 Ciclo de un motor Diésel de cuatro tiempos

2.2 Ciclo ideal Diésel

El motor de combustión interna a Diésel, generalmente es utilizado con Diésel, no obstante, otro tipo de combustibles pueden utilizarse, tal como aceites ligeros de origen mineral o vegetal como el aceite de girasol (Juntadeandalucia, 2004) .

2.2.1 Tiempos del motor Diésel

a) Tiempo 1° Admisión. (Transformación isobara 0-1): En este momento el pistón se encuentra en el PMS, se abre la válvula de admisión, se inicia el descenso del pistón hacia el PMI, entrando en el cilindro sólo comburente (aire).

b) Tiempo 2° Compresión. (Transformación adiabática 1-2): Cuando el pistón llega al PMI se cierra la válvula de admisión y el pistón inicia su ascenso hasta el PMS comprimiendo el aire. Esta compresión eleva la temperatura del aire (W =trabajo neto).

c) Tiempo 3° Combustión-expansión. (Transformación isobárica 2-3 y adiabática 3-4): Cuando el pistón se encuentra próximo al PMS, por el inyector, se introduce el combustible a gran presión, produciéndose una explosión como consecuencia del calor desprendido en el

roce del aire con el combustible, aumentando considerablemente la presión dentro del cilindro. En este momento se inicia la única carrera útil del ciclo haciendo que el pistón pase desde el PMS al PMI.

d) Tiempo 4° Expulsión o escape. (Transformación isócara (volumen cte.) 4-1 e isóbara 1-0): Cuando el pistón llegue al PMI se abre la válvula de escape provocando la evacuación de los gases quemados a la atmósfera. El resto de los gases son expulsados por el pistón en su ascenso al PMS. Cuando llega al PMS se cierra la válvula de escape y se abre la de admisión iniciándose un nuevo ciclo con el descenso del pistón.

Q_1 = Calor generado en la combustión, Q_2 =Calor cedido al ambiente o perdido.

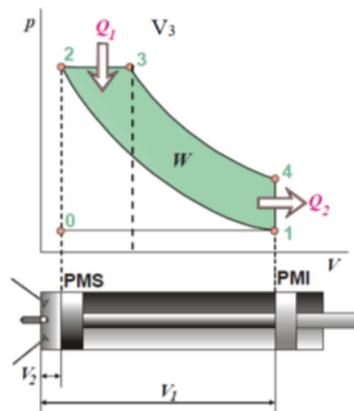


Figura 2. 4 Ciclo termodinámico del motor Diésel

2.3 Análisis termodinámico del motor Diésel (Ciclo teórico Motor CI, 2010)

2.3.1 Rendimiento teórico (η_T)

Considerando al motor como un sistema cerrado, en un cilindro y un ciclo se cumplirá:

$$\eta_T = \frac{w}{Q_1} = \frac{Q_1 - |Q_2|}{Q_1} = 1 - \frac{|Q_2|}{Q_1}$$

Por otra parte, si consideramos al aire como un gas ideal y estudiamos el trabajo producido en las diferentes transformaciones termodinámicas, obtendríamos la siguiente ecuación:

$$\eta_T = 1 - \frac{1}{\gamma} \cdot \frac{1}{\epsilon^{\gamma-1}} \cdot \frac{\tau^\gamma - 1}{\tau - 1}$$

Donde:

Ecuación conocida como relación de compresión:

$$\epsilon = R_c = \frac{V_1}{V_2}$$

τ = Relación de combustión a presión constante (relación de expansión)

$$\tau = \frac{V_3}{V_2}$$

γ = Coeficiente adiabático, C_p = Calor específico a presión constante, C_v = Calor específico a volumen constante.

$$\gamma = \frac{C_p}{C_v}$$

V_1 = Volumen total del cilindro, se obtiene cuando el pistón se encuentra en el PMI.

V_2 = Volumen de la cámara de combustión, es el volumen del cilindro que queda cuando el pistón se encuentra en el PMS.

Como se puede ver, la eficiencia de un motor diesel es función de ϵ , razón de compresión (V_1/V_2) y de τ , razón de expansión, (V_1/V_3).

Uno de los aspectos que ha favorecido la expansión de los motores Diésel es su eficiencia térmica (relación entre el trabajo realizado y la energía suministrada por el combustible). Mientras que los motores Diésel presentaban valores máximos de eficiencia del 48% en el año 2000, los motores de gasolina solo alcanzaban valores del 35% (Eberhardt, 2000).

En estudios realizados por el Departamento de Energía de los Estados Unidos (U.S. Department of Energy's), se registraron eficiencias de entre 55 a 63 % en los motores diesel más avanzados (Department of Energy, 2003).

2.4 Modelo del sistema de sobrealimentación + EGR de referencia desarrollado en Simulink de MATLAB por Salcedo et al. (Salcedo, J. V.; Martínez, M., 2007)

2.4.1. El motor Diésel con Turbocompresor

Dentro de los motores diésel el sobrealimentado con EGR es de los más utilizados, por las prestaciones que ostenta. El motor diésel con turbocompresor en su forma básica está compuesto de los elementos mostrados en la figura 2.5, los cuales se describen a continuación:

- a) **Compresor.** Este dispositivo tiene la función de incrementar la presión del aire admitido, haciendo posible la alimentación de una mayor cantidad de aire fresco hacia el interior de los cilindros del motor.
- b) **Interenfriador (Intercooler).** Consiste en un intercambiador de calor, cuya finalidad es enfriar el aire que sale del compresor antes de ser ingresado a los cilindros, a menor temperatura disminuye la densidad por lo que una mayor cantidad se podrá introducir en los cilindros.
- c) **Colector de admisión.** Se puede ver como la parte del proceso donde se lleva a cabo la mezcla del aire saliente del inter-enfriador y de los gases recirculados desde el escape (EGR).
- d) **Colector de escape.** Ensanchamiento existente a la salida de los cilindros en el que se acumulan de forma temporal los gases de escape, y que conecta con la turbina y con el EGR.
- e) **Circuito de EGR.** Es un tramo de tubo con una válvula de apertura variable (válvula de EGR) que conecta el colector de escape con el de admisión. A través de este arreglo mecánico se lleva a cabo la recirculación de los gases de escape hacia el colector de admisión (EGR).
- f) **Turbina.** Es una máquina térmica que utiliza la temperatura y presión de los gases de escape para generar la energía mecánica y mover el compresor.

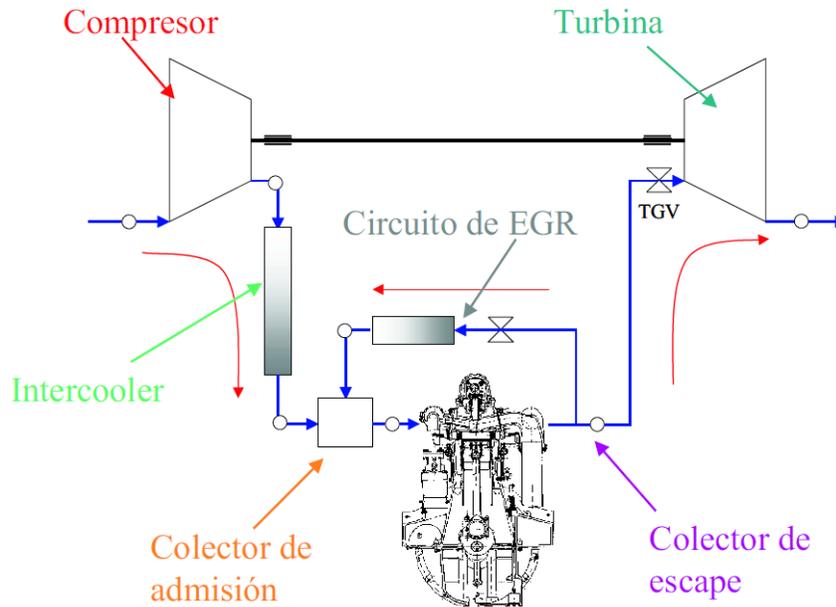


Figura 2. 5 Diagrama de un motor diésel con turbocompresor. Salcedo et al. (2001)

2.4.2. Modelo en Simulink de Matlab

El modelo que se utilizó como base para este trabajo es un modelo desarrollado por el Departamento de Motores Térmicos de la Universidad Politécnica de Valencia (Salcedo, et. al, 2001). Dicho modelo ha sido diseñado tomando las ecuaciones que describen el comportamiento de cada componente del conjunto (ver la figura 2.5: compresor + intercooler + motor + EGR + Turbina).

Se programaron en Simulink de MATLAB los bloques que contienen las ecuaciones que describen el comportamiento de cada uno de los elementos (véase la figura 2.6) que forman parte del motor de combustión interna diésel. Para llevar a cabo la simulación es posible modificar las variables siguientes:

1. Régimen de giro del motor (N)
2. Gasto másico de combustible
3. Apertura EGR
4. Apertura TGV
5. Temperatura a la salida del “intercooler” (T2b)
6. Temperatura del aire exterior (Ti)

Las variables de salida más importantes que proporciona este modelo son:

1. Gasto másico de aire entregado por el compresor (\dot{m}_a)
2. Presión en el colector de admisión (Pa)
3. Gasto másico recirculado por EGR (\dot{m}_{EGR})

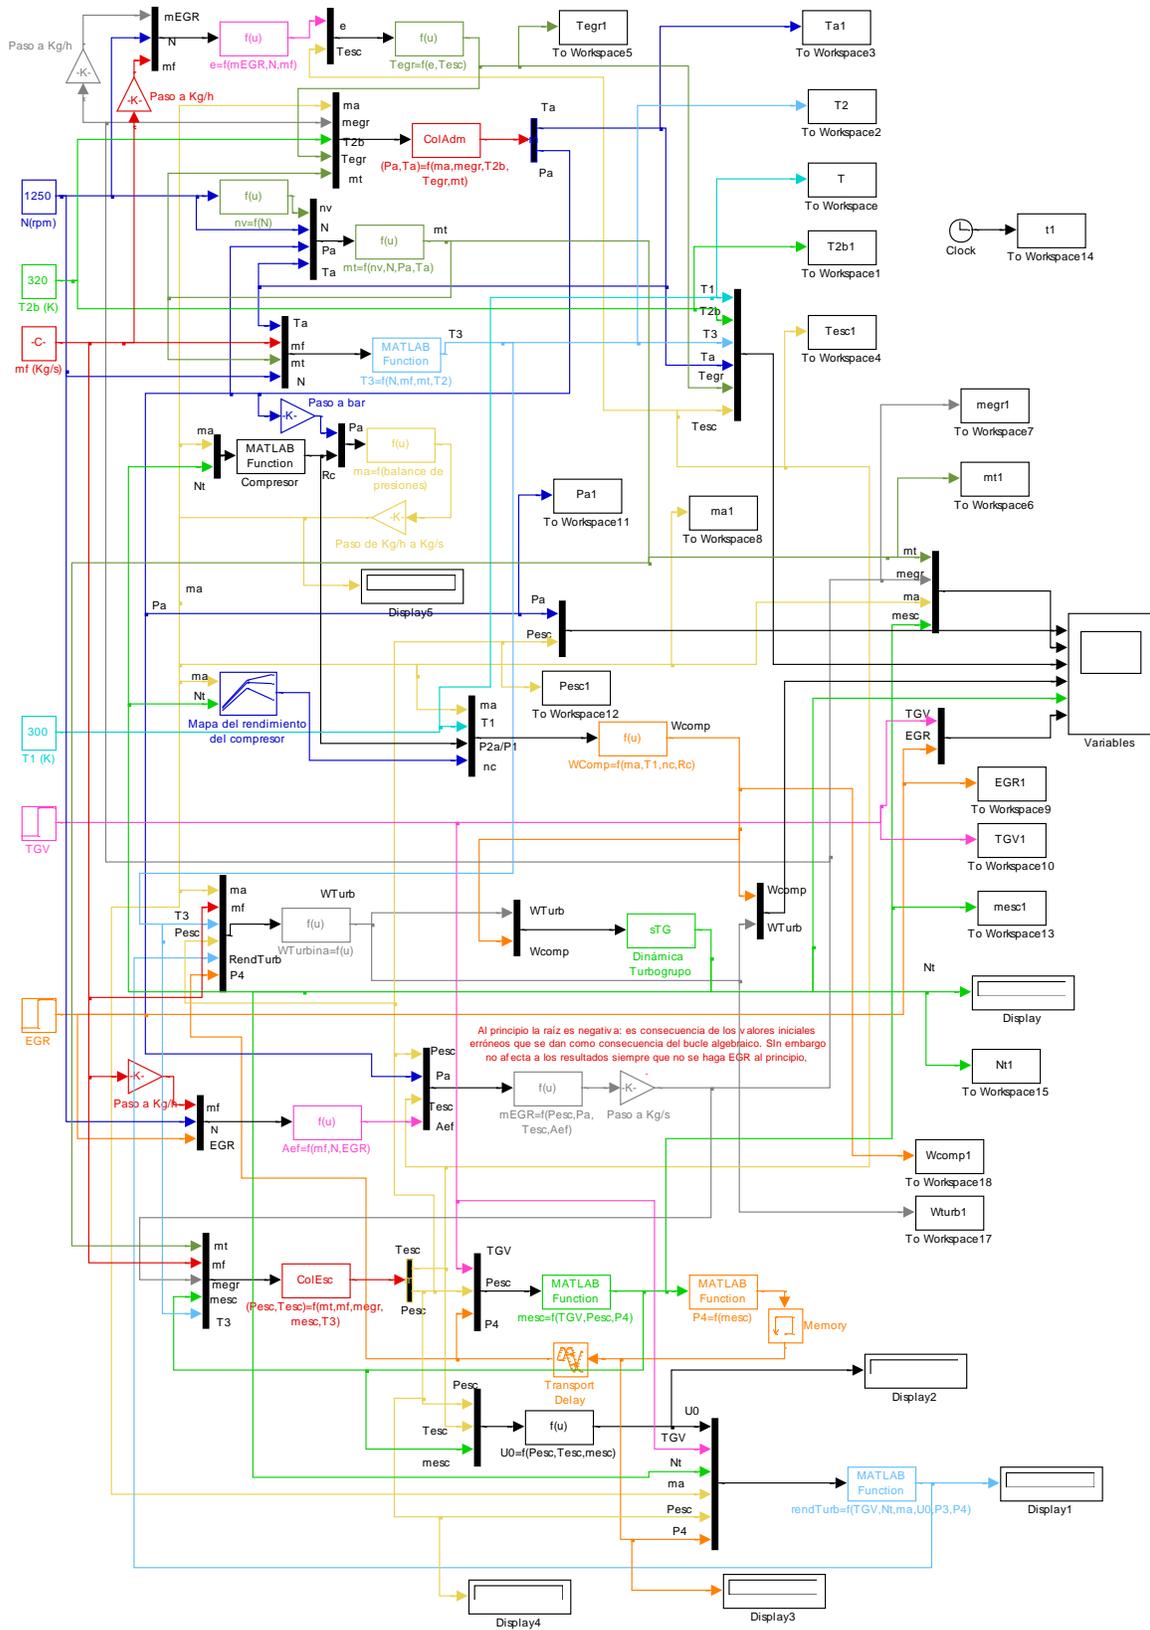


Figura 2. 6 Modelo del motor en Simulink. (Salcedo, J. V.; Martínez, M., 2007)

CAPÍTULO III
MÉTODOS DE
IDENTIFICACIÓN DE
SISTEMAS

3.1. Introducción

El diseño de controladores continuos o discretos, ya sea mediante técnicas clásicas o modernas, requiere de un modelo del proceso que describa su comportamiento dinámico de manera adecuada. Dicho modelo permite al diseñador determinar y validar mediante simulación el ajuste de los parámetros del controlador que permitan obtener una respuesta que cumpla las especificaciones de diseño.

3.1.1. Definición de sistema

Un sistema es toda entidad en la que interactúan variables de diferentes tipos para producir señales observables. Las señales observables que son de mayor interés para el observador se denominan salidas del sistema, mientras que las señales que pueden ser manipuladas libremente por dicho observador son las entradas del mismo. El resto de señales que influyen en la evolución de las salidas pero no pueden ser manipuladas por el observador se denominan perturbaciones, mismas que a veces pueden ser medidas y otras tantas solo se observa su influencia en la salida del sistema.

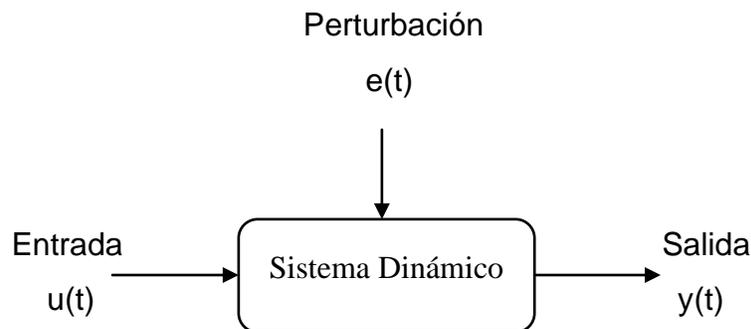


Figura 3. 1 Sistema dinámico con entrada $u(t)$, perturbación $e(t)$ y salida $y(t)$

3.1.2. Modelo de un sistema

Cuando se hace necesario conocer el comportamiento de un sistema en unas determinadas condiciones y ante unas determinadas entradas, se puede recurrir a la experimentación sobre dicho sistema y a la observación de sus salidas. Sin embargo, en muchos casos la

experimentación puede resultar compleja o incluso imposible de llevar a cabo, lo que hace necesario trabajar con algún tipo de representación que se aproxime a la realidad, y a la cual se conoce como modelo (López, 2006).

En términos generales, un modelo es una herramienta que permite predecir la respuesta de un sistema, en condiciones específicas, sin necesidad de experimentar sobre él.

3.1.3. Tipos de modelos

Los modelos de sistemas físicos pueden ser de muy diversos tipos. Una clasificación, en función del grado de formalismo matemático que poseen, es la siguiente:

- 1. Modelos mentales, intuitivos o verbales.** No presentan formalidad matemática. Por ejemplo, para conducir un coche, se hace uso de un modelo mental o intuitivo sobre el efecto que produce el movimiento del volante, y se podrá guiar el vehículo de manera correcta, sin que sea necesario caracterizar dicho efecto mediante ecuaciones matemáticas exactas.
- 2. Modelos no paramétricos.** Muchos sistemas quedan perfectamente caracterizados mediante un gráfico o tabla que describa sus propiedades dinámicas mediante un número no finito de parámetros. Por ejemplo, un sistema lineal queda definido mediante su respuesta al impulso o al escalón, o bien mediante su respuesta en frecuencia.
- 3. Modelos paramétricos o matemáticos.** Para aplicaciones específicas, puede ser necesario utilizar modelos que describan las relaciones entre las variables del sistema mediante expresiones matemáticas. Todo modelo matemático, por tanto, consta de una o varias ecuaciones que relacionan las entradas y salidas. De ahí que a los modelos matemáticos se les conozca más comúnmente como modelos paramétricos, ya que pueden definirse mediante una estructura y un número finito de parámetros. En función del tipo de sistema y de la representación matemática utilizada, los sistemas pueden clasificarse en:

a) **Determinísticos o estocásticos.** Se dice que un modelo es determinístico cuando expresa la relación entre entradas y salidas mediante una ecuación exacta. En contraposición, un modelo es estocástico si posee un cierto grado de incertidumbre. Estos últimos se definen mediante conceptos probabilísticos o estadísticos.

b) **Dinámicos o estáticos.** Un sistema es estático cuando la salida depende únicamente de la entrada en ese mismo instante (un resistor, por ejemplo, es un sistema estático). En estos sistemas existe una relación directa entre entrada y salida, independiente del tiempo. Un sistema dinámico es aquél en el que las salidas evolucionan con el tiempo tras la aplicación de una determinada entrada (por ejemplo, un circuito RC). En estos últimos, para conocer el valor actual de la salida es necesario conocer el tiempo transcurrido desde la aplicación de la entrada. Un sistema dinámico es un sistema que es descrito por ecuaciones diferenciales y/o ecuaciones de diferencias.

c) *Continuos o discretos.* Los sistemas continuos trabajan con señales continuas en el tiempo, y se caracterizan mediante ecuaciones diferenciales, frecuentemente representados por ecuaciones diferenciales. Los sistemas discretos trabajan con señales muestreadas, es decir, como resultado de mediciones discretas en el tiempo, y quedan descritos mediante ecuaciones de diferencias (Ljung, 1994).

3.1.4. Métodos de obtención de modelos

Existen dos métodos principales para obtener el modelo de un sistema:

1. **Modelado teórico.** Se trata de un método analítico, en el que se recurre a leyes básicas de la física para describir el comportamiento dinámico de un fenómeno o proceso.
2. **Identificación del sistema.** Se trata de un método experimental que permite obtener el modelo de un sistema a partir de datos reales recogidos de la planta bajo estudio. El modelado teórico tiene un campo de aplicación restringido a procesos muy sencillos de modelar, o aplicaciones en que no se requiera gran exactitud en el modelo obtenido. En muchos casos,

además, la estructura del modelo obtenido a partir del conocimiento físico de la planta posee un conjunto de parámetros desconocidos y que sólo se pueden determinar experimentando sobre el sistema real. De ahí la necesidad de recurrir a los métodos de identificación de sistemas.

En la práctica, lo ideal es recurrir a una mezcla de ambos métodos de modelado para obtener el modelo final. El uso de datos reales para identificar los parámetros del modelo provee a éste de una gran exactitud, pero el proceso de identificación se ve tanto más facilitado cuanto mayor sea el conocimiento sobre las leyes físicas que rigen el proceso (López, 2006).

3.2. Identificación de sistemas

Se entiende por identificación de sistemas a la obtención de forma experimental de un modelo que reproduzca con suficiente exactitud, para los fines deseados, las características dinámicas del proceso objeto de estudio.

3.2.1. El proceso de identificación

En términos generales, el proceso de identificación comprende los siguientes pasos:

1. Obtención de datos de entrada - salida. Para ello se debe excitar el sistema mediante la aplicación de una señal de entrada y registrar la evolución de sus entradas y salidas durante un intervalo de tiempo.
2. Tratamiento previo de los datos registrados. Los datos registrados están generalmente acompañados de ruidos indeseados u otro tipo de imperfecciones que puede ser necesario corregir antes de iniciar la identificación del modelo. Se trata, por tanto, de preparar los datos para facilitar y mejorar el proceso de identificación.
3. Elección de la estructura del modelo. Si el modelo que se desea obtener es un modelo paramétrico, el primer paso es determinar la estructura deseada para dicho modelo. Este punto

se facilita en gran medida si se tiene un cierto conocimiento sobre las leyes físicas que rigen el proceso.

4. Obtención de los parámetros del modelo. A continuación se procede a la estimación de los parámetros de la estructura que mejor ajustan la respuesta del modelo a los datos de entrada-salida obtenidos experimentalmente.

5. Validación del modelo. El último paso consiste en determinar si el modelo obtenido satisface el grado de exactitud requerido para la aplicación en cuestión. Si se llega a la conclusión de que el modelo no es válido, se deben revisar los siguientes aspectos como posibles causas:

a) El conjunto de datos de entrada-salida no proporciona suficiente información sobre la dinámica del sistema.

b) La estructura escogida no es capaz de proporcionar una buena descripción del modelo.

c) El criterio de ajuste de parámetros seleccionado no es el más adecuado.

Dependiendo de la causa estimada, deberá repetirse el proceso de identificación desde el punto correspondiente. Por tanto, el proceso de identificación es un proceso iterativo, cuyos pasos pueden observarse en el diagrama de la figura 3.2. (Ljung, System Identification, 1987).

3.2.2. Métodos de identificación

Existen diversos métodos de identificación, que pueden clasificarse según distintos criterios:

1. Dependiendo del tipo de modelo obtenido:

a) Métodos no paramétricos, que permiten obtener modelos no paramétricos del sistema bajo estudio. Algunos de estos métodos son: análisis de la respuesta transitoria, análisis de la respuesta en frecuencia, análisis de la correlación, análisis espectral, análisis de Fourier, etc.

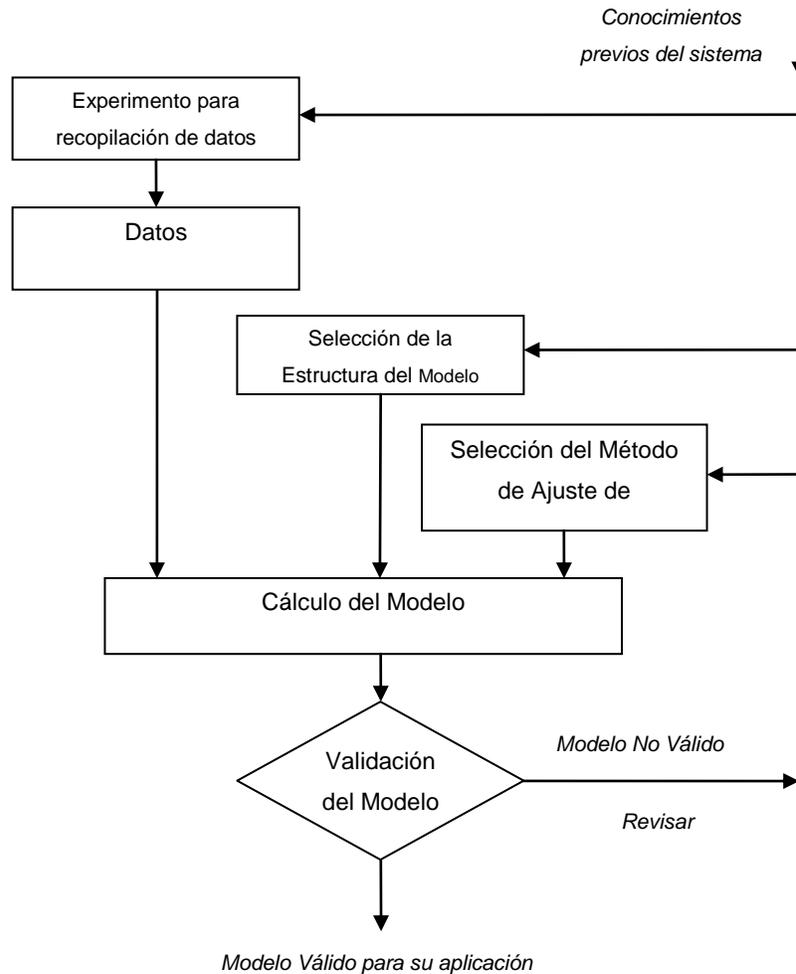


Figura 3. 2 Proceso de Identificación del Sistema

b) Métodos paramétricos, que permiten obtener modelos paramétricos. Estos métodos requieren la elección de una posible estructura del modelo, de un criterio de ajuste de parámetros, y por último de la estimación de los parámetros que mejor ajustan el modelo a los datos experimentales.

2. Dependiendo de la aplicación:

a) Métodos de identificación off-line (a posteriori), utilizados en aquellas aplicaciones en que no se requiera un ajuste continuado del modelo. En estos casos, se realiza la identificación previa de la planta, considerándose que la validez de los parámetros obtenidos no se verá alterada con el paso del tiempo.

b) Métodos de identificación on-line (identificación recursiva), en los que los parámetros se van actualizando continuamente a partir de los nuevos datos de entrada-salida obtenidos durante la evolución del proceso. Estos métodos son muy utilizados en sistemas de control adaptativo.

3. Dependiendo del criterio de ajuste de los parámetros. Existen diversos métodos matemáticos para ajustar los parámetros de una estructura a un conjunto de datos de entrada-salida. Algunos de los más utilizados en el campo de la identificación son el método de mínimos cuadrados y el método de las variables instrumentales.

3.3. Técnicas de identificación paramétrica

Los modelos paramétricos, a diferencia de los anteriores, quedan descritos mediante una estructura y un número finito de parámetros que relacionan las señales de interés del sistema (entradas, salida y perturbaciones). En muchas ocasiones es necesario realizar la identificación de un sistema del cual no se tiene ningún tipo de conocimiento previo. En estos casos, se suele recurrir a modelos estándar, cuya validez para un amplio rango de sistemas dinámicos ha sido comprobada experimentalmente. Generalmente estos modelos permiten describir el comportamiento de cualquier sistema lineal. La dificultad radica en la elección del tipo de modelo (orden del mismo, número de parámetros, etc.) que se ajuste satisfactoriamente a los datos de entrada - salida obtenidos experimentalmente.

3.3.1. Tipos de modelos paramétricos

Generalmente los modelos paramétricos se describen en el dominio discreto, puesto que los datos que sirven de base para la identificación se obtienen por muestreo. En el caso de que se requiera un modelo continuo, siempre es posible realizar una transformación del dominio discreto al continuo.

La expresión más general de un modelo discreto es del tipo:

$$s(t) = \eta(t) + w(t) \quad \text{ecuación 3.1}$$

donde $w(t)$ es el término que modela la salida debida a las perturbaciones, $\eta(t)$ la salida debida a la entrada, y $s(t)$ la salida medible del sistema. Cada uno de estos términos puede desarrollarse de la siguiente forma:

$$\eta(t) = G(q^{-1}, \theta) \cdot u(t) \quad \text{ecuación 3.2}$$

$$w(t) = H(q^{-1}, \theta) \cdot e(t) \quad \text{ecuación 3.3}$$

$$s(t) = A(q^{-1}, \theta) \cdot y(t) \quad \text{ecuación 3.4}$$

donde q^{-1} es el operador retardo, θ representa un vector de parámetros, $u(t)$ y $e(t)$ son la entrada al sistema y el ruido de entrada al mismo respectivamente e $y(t)$ es la salida de interés del sistema (que puede no coincidir con la salida medible).

Definiendo a $B(q^{-1})$ y $F(q^{-1})$ como polinomios:

$$B(q^{-1}) = b_1 \cdot q^{-nk} + b_2 \cdot q^{-nk} + \dots + b_{nb} \cdot q^{-nk-nb+1} \quad \text{ecuación 3.5}$$

$$F(q^{-1}) = 1 + f_1 \cdot q^{-1} + \dots + f_{nf} \cdot q^{-nf} \quad \text{ecuación 3.6}$$

$G(q^{-1}, \theta)$ y $H(q^{-1}, \theta)$ son cocientes de polinomios del tipo:

$$G(q^{-1}, \Theta) = \frac{B(q^{-1})}{F(q^{-1})} = \frac{b_1 \cdot q^{-nk} + b_2 \cdot q^{-nk} + \dots + b_{nb} \cdot q^{-nk-nb+1}}{1 + f_1 \cdot q^{-1} + \dots + f_{nf} \cdot q^{-nf}} \quad \text{ecuación 3.7}$$

$$H(q^{-1}, \Theta) = \frac{C(q^{-1})}{D(q^{-1})} = \frac{1 + c_1 \cdot q^{-1} + \dots + c_{nc} \cdot q^{-nc}}{1 + d_1 \cdot q^{-1} + \dots + d_{nd} \cdot q^{-nd}} \quad \text{ecuación 3.8}$$

y $A(q^{-1}, \Theta)$ un polinomio del tipo:

$$A(q^{-1}, \Theta) = 1 + a_1 \cdot q^{-1} + \dots + a_{n_a} \cdot q^{-n_a}$$

El vector de parámetros θ contiene los coeficientes a_i , b_i , c_i , d_i y f_i de las funciones de transferencia anteriores. La estructura genérica de estos modelos es por tanto:

$$A(q^{-1}) \cdot y(t) = G(q^{-1}, \Theta) \cdot u(t) + H(q^{-1}, \Theta) \cdot e(t) = \frac{B(q^{-1})}{F(q^{-1})} \cdot u(t) + \frac{C(q^{-1})}{D(q^{-1})} \cdot e(t) \quad \text{ecuación 3.10}$$

Para elegir la *estructura* de este tipo de modelos hay que determinar el orden de cada uno de los polinomios anteriores, es decir n_a , n_b , n_c , n_d , n_f y el retardo entre la entrada y la salida n_k . Una vez elegidos estos valores, sólo queda determinar el vector de coeficientes θ (a_i , b_i , c_i , d_i y f_i) que hacen que el modelo se ajuste a los datos de entrada - salida del sistema real.

En muchos casos, alguno de los polinomios anteriores no se incluye en la descripción del modelo, dando lugar a los siguientes casos particulares, entre otros:

Tabla 3. 1 Diversas estructuras de modelos paramétricos

Tipo de Modelo:	Condición:	Estructura resultante:
ARX (AutoRegressive with eXternal input)	$F(q^{-1})=D(q^{-1})=C(q^{-1})=1$	$A(q^{-1}) y(t) = B(q^{-1}) \cdot u(t) + e(t)$
Output Error (OE)	$C(q^{-1})=D(q^{-1})=A(q^{-1})=1$	$y(t) = \frac{B(q^{-1})}{F(q^{-1})} \cdot u(t) + e(t)$
ARMAX (AutoRegressive Moving Average with eXternal input)	$F(q^{-1})=D(q^{-1})=1$	$A(q^{-1}) y(t) = B(q^{-1}) \cdot u(t) + C(q^{-1}) \cdot e(t)$
Box Jenkins (BJ)	$A(q^{-1})=1$	$y(t) = \frac{B(q^{-1})}{F(q^{-1})} \cdot u(t) + \frac{C(q^{-1})}{D(q^{-1})} \cdot e(t)$

En la figura 3.3 se muestra el diagrama de bloques equivalente para cada uno de los modelos anteriores.

La anulación de alguno de los polinomios, resultando estructuras simplificadas, facilita el proceso de ajuste de parámetros. Cada una de las estructuras (ARX, ARMAX, OE o BJ) tiene sus propias características y debe ser elegida fundamentalmente en función del punto en el que se prevé que se añada el ruido en el sistema. En cualquier caso, puede ser necesario ensayar con varias estructuras y con varios órdenes dentro de una misma estructura hasta encontrar un modelo satisfactorio.

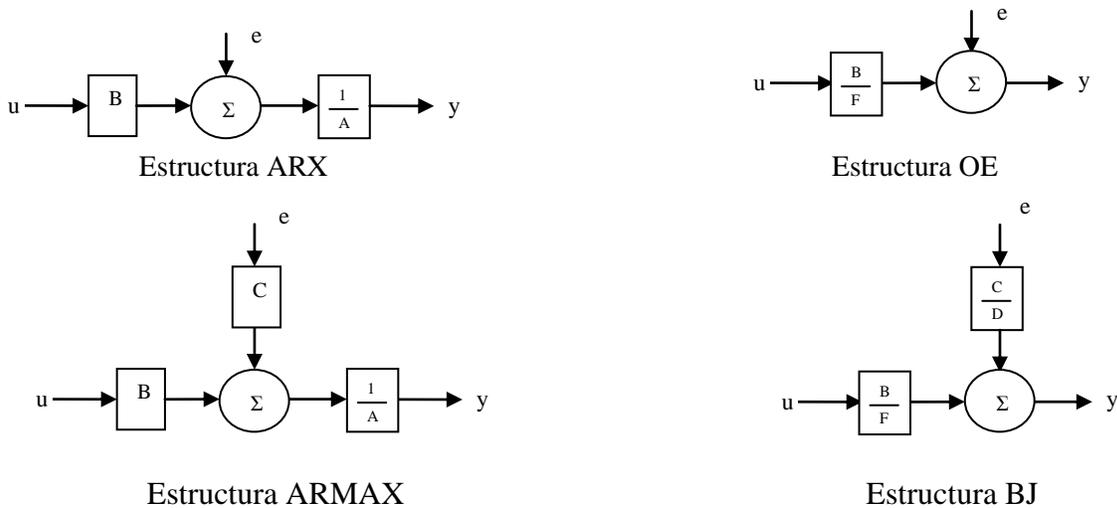


Figura 3. 3 Diagramas de bloques de las estructuras de la tabla 3.1.

Estructura ARX, donde “AR” se refiere a la parte autoregresiva, $A(q^{-1})$. $y(t)$ y la “X” a la entrada extra $B(q^{-1})$. $u(t)$ (llamada como la variable exógena en econometría).

Estructura ARMAX, otras estructuras no describen de manera adecuada las propiedades del elemento de disturbio, precisamente en esta estructura se adiciona un término que da flexibilidad para describir la ecuación del error como un promedio móvil de ruido blanco. La parte de promedio móvil (MA) corresponde al término $C(q^{-1}) \cdot e(t)$.

Los modelos de estructura de ecuaciones de error se ocupan de describir dónde las funciones de transferencia G y H tienen el polinomio A como un factor común en los denominadores. Sin embargo, desde un punto de vista físico, podría parecer más natural parametrizar estas funciones de transferencia de forma independiente. Si se supone que la relación entre la entrada y la salida sin disturbio, w , se puede escribir como una ecuación de diferencias lineales, y que los disturbios consisten en ruido blanco medible, entonces se obtiene el modelo del error en la salida (Output Error, OE).

Una alternativa de los modelos que ubican el error en la salida es el modelo BJ que mezcla las características de éstos, con un modelo ARMA, dando como resultado la siguiente estructura Ver también la figura 3.3:

$$y(t) = \frac{B(q^{-1})}{F(q^{-1})} \cdot u(t) + \frac{C(q^{-1})}{D(q^{-1})} \cdot e(t) \quad \text{ecuación 3.11}$$

3.3.2. Métodos para el ajuste de parámetros

Una vez elegida la estructura del modelo (tanto el tipo - ARX, ARMAX, BJ, OE...- como los órdenes de cada polinomio), es necesario determinar el valor de los parámetros del mismo que ajustan la respuesta del modelo a los datos de entrada - salidas experimentales. Es importante destacar, sin embargo, que esta etapa del proceso de identificación se ve facilitada por la existencia de herramientas de software que proporcionan diferentes algoritmos para el ajuste de parámetros. Una de estas herramientas es el *Toolbox de Identificación* de Matlab.

Existen varios métodos o criterios para realizar este ajuste de parámetros, entre los que cabe destacar el método de mínimos cuadrados y el de variables instrumentales.

3.3.2.1. Errores de predicción o residuos de un modelo

Todo modelo matemático es capaz de predecir el valor de la salida del sistema en función de las entradas y salidas en instantes anteriores. Se llama error de predicción $\varepsilon(t, \theta)$ a la diferencia entre la salida estimada por el modelo y la salida real del sistema en un determinado instante de tiempo:

$$\varepsilon(t, \theta) = y(t) - y_e(t, \theta) \quad \text{ecuación 3.12}$$

donde $y_e(t, \theta)$ es la salida estimada por el modelo en el instante t .

3.3.2.2. Regresión lineal

Se dice que una estructura posee regresión lineal cuando la salida estimada puede expresarse como:

$$y_e(t, \theta) = \varphi^T(t) \cdot \theta \quad \text{ecuación 3.13}$$

donde $\varphi^T(t)$ es un vector columna formado por las salidas y entradas anteriores (conocido como *vector de regresión*), y θ es el vector de parámetros del modelo.

El modelo ARX es un claro ejemplo de estructura con regresión lineal, definiendo:

$$\theta = [a_1 \ a_2 \ \dots \ a_{na} \ b_1 \ \dots \ b_{nb}]^T \quad \text{ecuación 3.14}$$

$$\varphi^T(t) = [-y(t-1) \ \dots \ -y(t-na) \ u(t-nk) \ \dots \ u(t-nk-nb+1)] \quad \text{ecuación 3.15}$$

3.3.2.3. Método de mínimos cuadrados (LSE)

Aplicando los criterios fijados en los dos apartados anteriores, la expresión del error de predicción es:

$$\varepsilon(t, \theta) = y(t) - \varphi^T(t) \cdot \theta \quad \text{ecuación 3.16}$$

Se define la siguiente función del error:

$$V_N(\theta) = \frac{1}{N} \sum_{t=1}^N \frac{1}{2} \cdot [y(t) - \varphi^T(t) \cdot \theta]^2 \quad \text{ecuación 3.17}$$

conocida como criterio de mínimos cuadrados para una regresión lineal.

Existe un valor de θ que minimiza la función anterior y que constituye la estimación del modelo por mínimos cuadrados:

$$\theta_{LSE} = \text{sol}\left\{\frac{1}{N} \sum_{t=1}^N \varphi^T(t) \cdot [y(t) - \varphi^T(t) \cdot \theta] = 0\right\} \quad \text{ecuación 3.18}$$

Para este vector de parámetros, la función de error V_N toma su valor mínimo, siendo éste la función de pérdidas del modelo estimado.

Una variante del método anterior, conocido como Criterio de Akaike consiste en minimizar otra función de pérdidas distinta a la anterior, que puede obtenerse a partir de ésta del siguiente modo:

$$V_{AIC} = V_N(\theta) \cdot (1 + 2 \cdot d/N) \quad \text{ecuación 3.19}$$

siendo “d” el número de parámetros del modelo y N el número de muestras de los datos de entrada-salida utilizados para su identificación.

3.3.2.4. Método de variables instrumentales

Mediante este método, el vector de parámetros debe cumplir la relación:

$$\theta_{IV} = \text{sol}\left\{\frac{1}{N} \sum_{t=1}^N \xi(t) \cdot [y(t) - \varphi^T(t) \cdot \theta] = 0\right\} \quad \text{ecuación 3.20}$$

donde los elementos del vector $\xi(t)$ son las llamadas *variables instrumentales*, que resultan de aplicar algún tipo de filtro lineal al vector de regresión lineal $\varphi(t)$. Este método es en realidad una generalización del método de mínimos cuadrados, que proporciona mejores resultados en aquellos casos en que existe algún tipo de correlación entre el ruido y la salida del sistema. (López, 2006).

3.4. Identificación mediante Redes Neuronales

3.4.1. Introducción

Las “redes neuronales artificiales” o simplemente “redes neuronales” constituyen una de las áreas de la inteligencia artificial que ha despertado mayor interés en los últimos años. La razón de esto es que las redes neuronales potencialmente son capaces de resolver problemas cuya solución por otros métodos convencionales resulta extremadamente difícil.

La cualidad más sobresaliente de las redes neuronales es que ellas son capaces de “aprender”. En lugar de programar a una red se le presenta una serie de ejemplos, a partir de los cuales ella aprende las relaciones principales que están implícitas en la base de datos de entrenamiento. Puesto que estas relaciones pueden ser fuertemente no-lineales, las redes pueden constituir entonces una herramienta muy general y potente para modelar procesos industriales de cualquier grado de complejidad.

Las redes neuronales son de gran utilidad para los ingenieros que emplean sistemas de control e identificación debido a su campo de acción, podemos atacar sistemas lineales y no lineales.

La figura 3.4 presenta un ejemplo de una red neuronal típica, conocida en la literatura como perceptrón multicapas. La red consiste de neuronas de procesamiento (círculos) y canales de

flujo de información entre las neuronas llamadas interconexiones. Los rectángulos son neuronas que simplemente almacenan entradas a la red. Cada neurona de procesamiento posee una cantidad limitada de memoria y realiza un cálculo local que transforma las entradas en la salida. Este cálculo se denomina la función de activación o función transferencial de la neurona. Las funciones transferenciales pueden ser lineales o no y consisten de ecuaciones algebraicas o diferenciales.

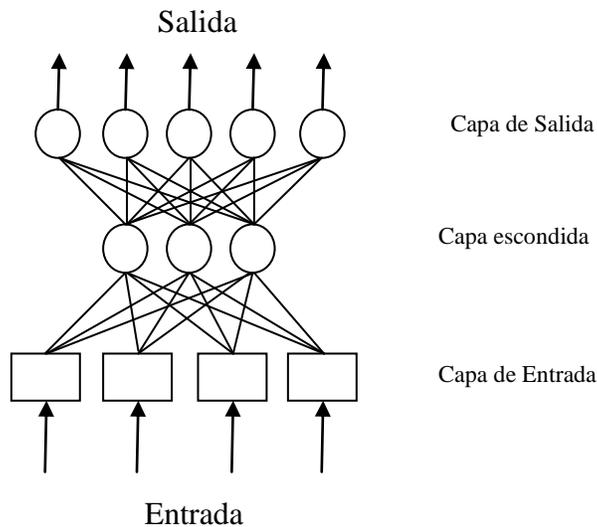


Figura 3. 4 Red Neuronal Perceptrón Multi-capas.

En la red mostrada en la figura 3.4, hay tres capas de neuronas: La capa de entrada, la escondida y la capa de salida. En algunas publicaciones la capa de entrada no se cuenta y desde este punto de vista la red de la figura 3.4 podrá considerarse un conjunto de dos capas. *Se adoptará la convención de que la capa de entrada se cuente como una más.*

3.4.2. Retropropagación

De acuerdo con un estudio reciente, existen más de 50 tipos de redes neuronales que han sido estudiadas y/o usadas en una gran diversidad de aplicaciones. Sin embargo, quizás la más extendida y utilizada para la identificación de procesos dinámicos y su control es la llamada red de retropropagación.

Una red de retropropagación típica puede esquematizarse tal como se muestra en la figura 3.4. El concepto de retropropagación se refiere a un método de entrenamiento de la red y por extensión se le llama “red de retropropagación” a aquella que se entrena mediante dicho método. Es conveniente aclarar que el método o algoritmo de retropropagación no es el único existente en la actualidad, no obstante, puede afirmarse que el método básico y sus modificaciones han sido las más exitosas en la solución de una gran diversidad de problemas prácticos. Entre las aplicaciones de este tipo de red podemos citar:

- Reconocimiento y síntesis de voz
- Reconocimiento de patrones visuales o imágenes
- Análisis de señales de sonar
- Aplicaciones en la defensa
- Diagnóstico médico
- Control de columnas de destilación y otros procesos

La red de retropropagación es un tipo de red neuronal que es capaz de desarrollar una aproximación tan fina como se quiera de cualquier función no lineal $y=f(x)$; a partir de un conjunto de pares de ejemplo x, y . Este método es una generalización de la ley de aprendizaje por el descenso más rápido presentada por Widrow y Hoff (1960); que analizaron una red neuronal de dos capas llamada ADALINE y desarrollaron un método de descenso local según la dirección del gradiente.

El método propuesto por Widrow y Hoff fue generalizado al caso de capas múltiples con el nombre de “algoritmo de retropropagación” (Werbos, 1974; Rumelhart y McClelland, 1986). La cuestión del número de capas en una red es muy importante tal como demuestran Minsky y Papert (1972) en su texto clásico “Perceptrons”. Ellos mostraron que una red de dos capas del tipo estudiado hasta entonces estaba limitada en cuanto al espectro de problemas que podría resolver y especularon sobre que el estudio de redes multicapas sería un área estéril. No obstante, la experiencia ha demostrado que esa especulación era incorrecta.

En efecto, las redes multicapas pueden dar resultados que son imposibles de alcanzar con las redes de dos capas. Como ha sido discutido por Rumelhart y McClelland (1986), la adición de capas escondidas permite al algoritmo de retropropagación desarrollar una “representación

interna” del problema que puede ser vital para su solución. Parece ser que la presencia de una o más capas escondidas le da a la retropropagación nuevas dimensiones en términos de su habilidad para “aprender” la representación de una función arbitraria $f(x)$.

3.4.3. Algoritmos de Cálculo

Consideremos la red representada en forma simplificada en la figura 3.5 y supongamos que se dispone de un conjunto de pares de datos, $x^p, y^p, p=1,2, \dots, N$.

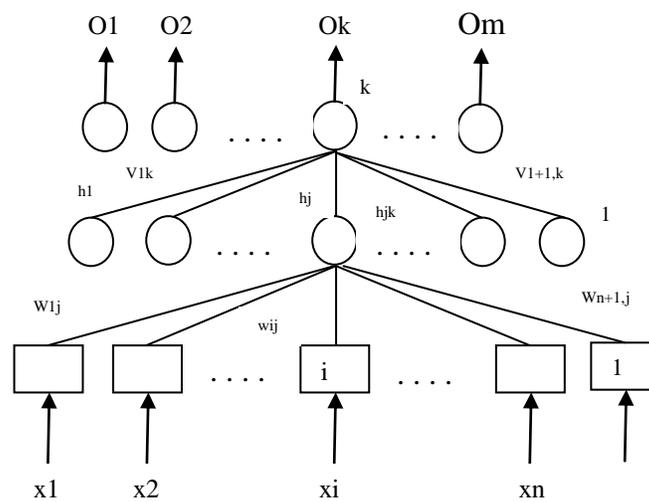


Figura 3. 5 Red Neuronal simplificada.

Para la neurona j de la capa escondida, definimos la función de excitación, correspondiente a la muestra p de los datos:

$$S_j^p = \sum_{i=1}^n w_{ij}^p x_i^p + w_{n+1,j}^p \quad \text{ecuación 3.21}$$

Es conveniente aclarar en este punto que los datos de entrada y de salida x_i, y_i deben estar normalizados en el intervalo 0-1. Los coeficientes w_{ij}, v_{jk} , se denominan “pesos” y a la entrada $n+1$, cuyo valor es fijado en el valor 1, se le conoce como “bias”. Este último elemento

permite que la red pueda modelar sistemas en que las salidas pueden tener valores distintos de cero cuando todas las entradas son cero.

La salida de la neurona j de la capa escondida se calcula generalmente como una función no-lineal de la excitación aunque en algunos casos particulares pueden ser también una función lineal. Por el momento se define a la función no lineal de salida o función de activación como la función sigma, tanto para las neuronas de la capa escondida como para las de la capa de salida. Esta función presenta considerables ventajas dada su simplicidad aunque es posible utilizar otras funciones como la tangente hiperbólica, la función de Gauss, etc. La forma de la función sigma o sigmoide, se represente en la figura 3.6.

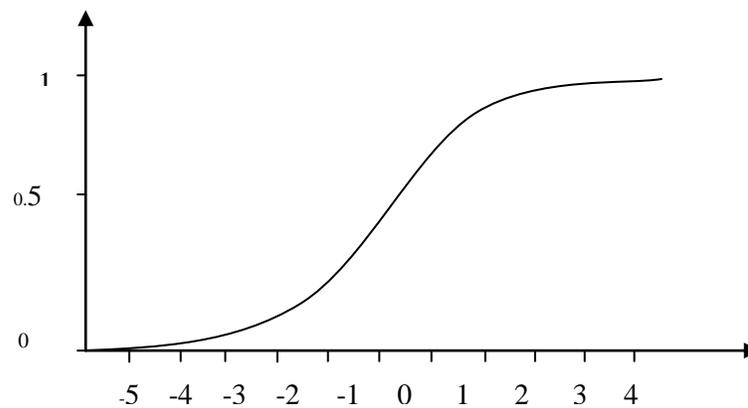


Figura 3. 6 Función Sigma o Sigmoide.

Entonces la salida de la neurona j de la capa escondida, se expresa:

$$h_{jp} = f(S_{jp}) = \frac{1}{1+e^{-S_{jp}}} \quad \text{ecuación 3.22}$$

La excitación de la neurona k de la capa de salida, se calcula en forma análoga, mediante la expresión:

$$r_k^p = \sum_{j=1}^1 v_{jk^p} h_j^p + v_{l+1,k^p} \quad \text{ecuación 3.23}$$

Y por último, la salida de la neurona k de la capa de salida se expresa como:

$$O_{k^p} = f(r_{k^p}) = \frac{1}{1+e^{-r_{k^p}}} \quad \text{ecuación 3.24}$$

Definimos ahora al error en la salida k, para la muestra p como:

$$e_{k^p} = y_{k^p} - O_{k^p} \quad \text{ecuación 3.25}$$

Y el criterio a minimizar en la muestra p:

$$E_p = \frac{1}{2} \sum_{k=1}^m (e_{k^p})^2 = \frac{1}{2} \sum_{k=1}^m (y_{k^p} - O_{k^p})^2 \quad \text{ecuación 3.26}$$

O también:

$$E_p = \frac{1}{2} \sum_{k=1}^m (y_{k^p} - f(r_{k^p}))^2 \quad \text{ecuación 3.27}$$

El proceso de aprendizaje de la red consiste entonces en presentar secuencialmente las entradas x_i^p ($p = 1, \dots, M$) ($i = 1, 2, \dots, n$), calcular las salidas de la red O_k^p ($k = 1, 2, \dots, m$) ($p = 1, 2, \dots, M$), los errores e_k^p y el criterio E_p y aplicar algún procedimiento de minimización de la función E_p con respecto a los coeficientes de peso w_{ij} y v_{jk} de manera que estos se vayan aproximando paulatinamente a los valores que garantizan un error mínimo entre las salidas de la red O_k y los datos de salida y_k .

Este procedimiento se repite tantas veces como sea necesario, es decir, los vectores de datos x^p e y^p se utilizan reiteradamente hasta tanto el error en cada salida y el criterio E_p , para $p=1, 2, \dots, N$, se encuentren por debajo del límite prefijado. Una vez lograda esta condición, se dice que la red está entrenada, lo que significa que ella será capaz de reproducir la función $y=f(x)$ con suficiente exactitud si los datos de entrenamiento han sido bien seleccionados y suficientes. A cada ciclo de uso de los datos de entrenamiento suele denominársele “época” en el argot de las redes neuronales.

Para minimizar la función E_p con respecto a los coeficientes de peso w_{ij} y v_{jk} se puede utilizar el método del “descenso más rápido” (Steepest descent) que consiste en moverse siempre en la dirección del negativo del gradiente de la función E_p con respecto a los coeficientes w_{ij} y v_{jk} .

El gradiente de la función E_p es un vector multidimensional cuyas componentes son las derivadas parciales $\frac{\partial E_p}{\partial v_{jk^p}}$ y $\frac{\partial E_p}{\partial w_{ij^p}}$ o sea:

$$\nabla E_p = \begin{bmatrix} \frac{\partial E_p}{\partial v_{jk^p}} \\ \frac{\partial E_p}{\partial w_{ij^p}} \end{bmatrix} \quad \text{ecuación 3.28}$$

Se calculan en primer lugar las derivadas parciales con respecto a las neuronas de la capa de salida, lo que resulta más simple:

$$\frac{\partial E_p}{\partial v_{jk^p}} = \frac{\partial E_p}{\partial O_{k^p}} \frac{\partial O_{k^p}}{\partial r_{k^p}} \frac{\partial r_{k^p}}{\partial v_{jk^p}} \quad \text{ecuación 3.29}$$

$$\frac{\partial E_p}{\partial O_{k^p}} = \frac{\partial \{\sum_{k=1}^m (y_{k^p} - O_{k^p})^2\}}{\partial O_{k^p}} = -(y_{k^p} - O_{k^p}) \quad \text{ecuación 3.30}$$

$$\frac{\partial O_{k^p}}{\partial r_{k^p}} = \frac{\partial \left\{ \frac{1}{1 + e^{-r_{k^p}}} \right\}}{\partial r_{k^p}} = \frac{e^{-r_{k^p}}}{(1 + e^{-r_{k^p}})^2} = O_{k^p}(1 - O_{k^p}) \quad \text{ecuación 3.31}$$

$$\frac{\partial r_{k^p}}{\partial v_{jk^p}} = \frac{\partial \{\sum_{j=1}^1 (v_{jk^p} h_{j^p} + v_{l+1,k^p})\}}{\partial v_{jk^p}} \quad \text{ecuación 3.32}$$

Sustituyendo (3.30), (3.31) y (3.32) en (5.29), tenemos que:

$$\frac{\partial E_p}{\partial v_{jk^p}} = -(y_{k^p} - O_{k^p}) O_{k^p} (1 - O_{k^p}) h_{j^p} \quad \text{ecuación 3.33}$$

Definimos ahora:

$$\delta_{k^p} = -(y_{k^p} - O_{k^p}) O_{k^p} (1 - O_{k^p}) \quad \text{ecuación 3.34}$$

Y sustituyendo (3.34) en (3.33), tenemos entonces:

$$\frac{\partial E_p}{\partial v_{jk^p}} = -\delta_{k^p} h_{j^p} \quad \text{ecuación 3.35}$$

La segunda parte del gradiente de E_p requiere del cálculo de sus derivadas parciales con respecto a los coeficientes de peso w_{ij} que conectan a la capa de entrada con la capa escondida.

A continuación procedemos a realizar dicho cálculo.

En primer lugar, se retoma la expresión que define al criterio E_p :

$$E_p = \frac{1}{2} \sum_{k=1}^m (y_{k^p} - f(r_{k^p}))^2 \quad \text{ecuación 3.36}$$

Y teniendo en cuenta la definición de r_{k^p} según (3.23), podremos escribir:

$$E_p = \frac{1}{2} \sum_{k=1}^m (y_{k^p} - f(\sum_{j=1}^1 v_{jk^p} h_j^p + v_{l+1,k^p}))^2 \quad \text{ecuación 3.37}$$

Sabemos además, que de acuerdo con (3.21) y (3.22):

$$h_j^p = f(\sum_{i=1}^n w_{ij^p} x_i^p + w_{n+1,j^p}) \quad \text{ecuación 3.38}$$

Aplicando ahora la regla de la cadena de la derivación y teniendo en cuenta las relaciones (3.36) y (3.38), se llega a:

$$\frac{\partial E_p}{\partial w_{ij}^p} = \left[\sum_{k=1}^m \left(\frac{\partial E_p}{\partial O_{k^p}} \frac{\partial O_{k^p}}{\partial r_{k^p}} \frac{\partial r_{k^p}}{\partial h_{j^p}} \right) \right] \frac{\partial h_{j^p}}{\partial S_{j^p}} \frac{\partial S_{j^p}}{\partial w_{ij}^p} \quad \text{ecuación 3.39}$$

$$= - \left(\sum_{k=1}^m (y_{k^p} - O_{k^p}) O_{k^p} (1 - O_{k^p}) v_{jk^p} \right) h_{j^p} (1 - h_{j^p}) x_{i^p} \quad \text{ecuación 3.40}$$

$$\frac{\partial E_p}{\partial w_{ij}^p} = - \left(\sum_{k=1}^m \delta_{k^p} v_{jk^p} \right) h_{j^p} (1 - h_{j^p}) x_{i^p} \quad \text{ecuación 3.41}$$

Definimos:

$$\Delta_{j^p} = \left(\sum_{k=1}^m \delta_{k^p} v_{jk^p} \right) h_{j^p} (1 - h_{j^p}) \quad \text{ecuación 3.42}$$

Y sustituyendo (3.42) en (3.41), tenemos que:

$$\frac{\partial E_p}{\partial w_{ij}^p} = - \Delta_{j^p} x_{i^p} \quad \text{ecuación 3.43}$$

Teniendo en cuenta las expresiones (3.35) y (3.43), tenemos que:

$$\nabla E_p = - \begin{bmatrix} \delta_{k^p} h_{j^p} \\ \Delta_{j^p} x_{i^p} \end{bmatrix} \quad \text{ecuación 3.44}$$

El algoritmo de retropropagación aplicado al entrenamiento de las neuronas de una red de tres capas, consiste en aplicar el método del descenso más rápido, o en otras palabras, moverse en la dirección del negativo del gradiente, dando un paso de actualización de los valores de los coeficientes de peso v_{jk^p} y w_{ij^p} con cada par de vectores de entrada y salida x_p , y_p , o sea:

$$\begin{bmatrix} v_{jk^p} \\ w_{ij^p} \end{bmatrix} = \begin{bmatrix} v_{jk^{p-1}} \\ w_{ij^{p-1}} \end{bmatrix} - \eta \nabla E_p \quad \text{ecuación 3.45}$$

ó

$$\begin{bmatrix} v_{jk^p} \\ w_{ij^p} \end{bmatrix} = \begin{bmatrix} v_{jk^{p-1}} \\ w_{ij^{p-1}} \end{bmatrix} - \eta \begin{bmatrix} \delta_{k^p} h_{j^p} \\ \Delta_{j^p} x_{i^p} \end{bmatrix} \quad \text{ecuación 3.46}$$

De donde son evidentes las relaciones:

$$v_{jk^p} = v_{jk^{p-1}} - \eta \delta_{k^p} h_{j^p} \quad \text{ecuación 3.47}$$

$$w_{ij^p} = w_{ij^{p-1}} - \eta \Delta_{j^p} x_{i^p} \quad \text{ecuación 3.48}$$

Donde η (eta) es una constante que se denomina constante de aprendizaje.

Se ha demostrado experimentalmente que una forma de acelerar la convergencia en el proceso de aprendizaje es incluir un término proporcional al cambio realizado en los coeficientes de peso en la muestra anterior. Entonces definimos:

$$I_{v_{jk^p}} = \eta \delta_{k^{p-1}} h_{j^{p-1}} + \alpha I_{v_{jk^{p-1}}} \quad \text{ecuación 3.49}$$

$$I_{w_{ij^p}} = \eta \Delta_{j^{p-1}} x_{i^{p-1}} + \alpha I_{w_{ij^{p-1}}} \quad \text{ecuación 3.50}$$

Y:

$$v_{jk^p} = v_{jk^{p-1}} + \eta \delta_{k^p} h_{j^p} + \alpha I_{v_{jk^p}} \quad \text{ecuación 3.51}$$

$$w_{ij^p} = w_{ij^{p-1}} - \eta \Delta_{j^p} x_{i^p} + \alpha I_{w_{ij^p}} \quad \text{ecuación 3.52}$$

Donde el coeficiente α se denomina coeficiente de momentum y sus valores son generalmente menores que los de η .

La utilización del coeficiente de momentum en las ecuaciones de actualización de los coeficientes de peso tiene también el efecto benéfico de disminuir considerablemente la probabilidad de que el algoritmo de minimización quede atrapado en un mínimo local.

Los valores específicos de los coeficientes η y α deben escogerse experimentalmente; como valores típicos puede partirse de los valores $\eta=0.5$ y $\alpha=0.1$. Hemos comprobado

experimentalmente que valores mayores de η aunque pueden resultar en una convergencia más rápida, pueden conducir a una aproximación oscilatoria en la convergencia de los coeficientes v_{jk} y w_{ij} . Se ha intentado también con relativo éxito, el uso de coeficientes de aprendizaje y de momentum variables, partiendo de valores menores hasta lograr la aproximación a un entorno de los valores estacionarios de v_{jk} y w_{ij} y después ir sucesivamente aumentando a η y α .

Es importante destacar que la estrategia de entrenamiento de una red neuronal mediante el algoritmo de retropropagación explicado hasta aquí, tiene algunas particularidades que lo distinguen de un problema convencional de optimización. Si se dispone de una muestra de M pares de valores x^p , y^p de entrada y salida, estos datos serán presentados secuencialmente a la red, calculándose una actualización de los coeficientes de peso w_{ij} , v_{jk} para cada par de datos, hasta agotarlos todos, es decir, para $p= 1,2, \dots, M$. A este ciclo de entrenamiento se le llama generalmente una “época”. Es muy frecuente que un solo ciclo o época no sea suficiente para lograr un valor aceptablemente pequeño del criterio E_p para todos los valores de p y entonces es necesario reciclar los datos, o en otras palabras, comenzar una nueva época. Dependiendo del tamaño de la muestra de entrenamiento, se necesitarán más o menos épocas, pudiendo ser su número desde unas decenas hasta cientos o miles.

3.4.4. Identificación de procesos dinámicos mediante redes neuronales

El problema de la identificación de procesos dinámicos mediante redes neuronales tiene algunas particularidades que lo distinguen de la mayoría de los ejemplos que aparecen en la literatura donde generalmente se trata de la modelación de relaciones no-lineales estacionarias del tipo $y=f(x)$. Consideremos en primer lugar el ejemplo de un proceso lineal representado mediante un modelo de regresión simple:

$$y(t) = \sum_{i=1}^n a_i y(t - i) + \sum_{i=1}^m b_i u(t - i) \quad \text{ecuación 3.53}$$

Este modelo puede representarse mediante una red lineal de dos capas, tal como se muestra en la figura 3.7.

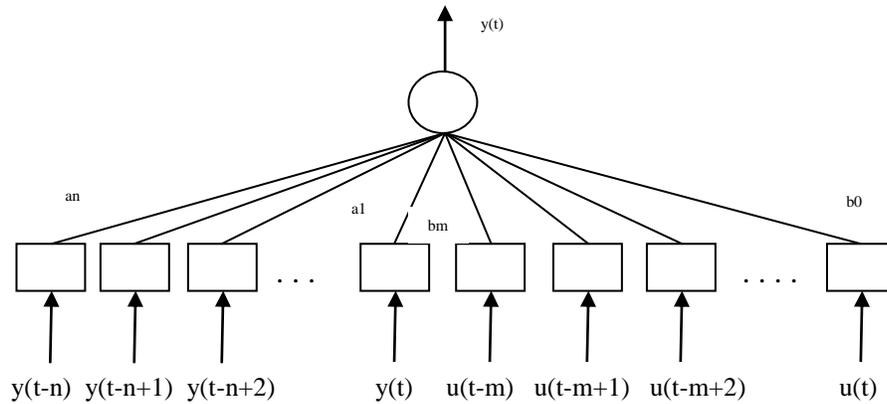


Figura 3. 7 Modelo de una red lineal de dos capas

Consideremos ahora una generalización del modelo de regresión, en la que se asume la relación dinámica no-lineal:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n), u(t), u(t-1), \dots, u(t-m)) \quad \text{ecuación 3.54}$$

Este sistema dinámico no lineal puede representarse mediante la siguiente red de tres capas:

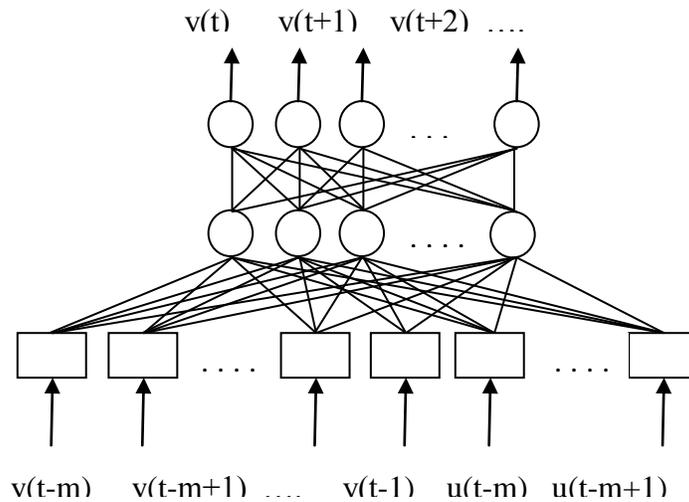


Figura 3. 8 Modelo de un sistema dinámico no lineal

Esta red puede entrenarse utilizando el método de retropropagación discutido anteriormente. La ventaja es que se dispone entonces de un procedimiento de identificación de mucha mayor generalidad aplicable teóricamente a cualquier tipo de sistema dinámico. Debe tenerse en

cuenta que las salidas de la red deben normalizarse en el intervalo 0-1, dado que las funciones sigma involucradas dan salidas sólo en ese intervalo.

No existe un procedimiento teórico que permita definir el número de neuronas en cada capa, pero pueden darse algunas orientaciones prácticas. La selección del número de neuronas de la capa de entrada es en cierta forma equivalente a la selección del orden de un modelo de regresión en el caso de la identificación de modelos lineales mediante el método de mínimos cuadrados. El número de valores anteriores de las entradas y salidas debe escogerse lo más pequeño posible, 2 por ejemplo, e irlos aumentando sucesivamente hasta que se logre un valor pequeño del error de predicción de la red.

El número de neuronas de la capa de salida es bastante arbitrario, en muchos casos basta una sola neurona (caso de procesos monovariantes), pero en muchos casos se incluyen adicionalmente varias predicciones de la salida, sobre todo cuando la red se va a utilizar como parte de un sistema de control predictivo óptimo o en el caso de procesos con retardo puro.

El número de neuronas de la capa escondida generalmente es una fracción del número de neuronas de la capa de entrada, por ejemplo la mitad, pero su número preciso debe seleccionarse adecuadamente en cada caso particular.

Otro tipo de estructura que ha sido propuesta en la literatura para una red que modela un proceso dinámico se inspira en el modelo impulsivo o de convolución de un sistema lineal:

$$y(t) = \sum_{i=0}^t g(i)u(t-i) \quad \text{ecuación 3.55}$$

En este modelo generalmente se limita el número de términos anteriores de la variable de entrada que influyen sobre la salida en el tiempo t , pero de todas formas, ese número puede ser bastante grande (varias decenas, por ejemplo). El modelo no lineal correspondiente sería:

$$y(t) = f(u(t), u(t-1), \dots, u(t-q)) \quad \text{ecuación 3.56}$$

al que corresponde una red en la que el número de neuronas en la capa de entrada sería q y el vector de entrada en el tiempo t tendría la forma:

$$x^T(t)=[u(t-q), u(t-q+1), \dots, u(t)] \quad \text{ecuación 3.57}$$

La desventaja de esta red neuronal es que el número de neuronas de la capa de entrada (y también de la capa escondida) generalmente es mayor que el correspondiente al de un modelo de regresión. No obstante, se reportan buenos resultados en la aproximación de sistemas dinámicos fuertemente no-lineales, usando esta estructura.

En muchos esquemas de control basados en redes neuronales resulta necesario contar con la llamada “red inversa”; que consiste en considerar la entrada de la red como la salida del sistema y viceversa, por ejemplo, la red inversa de la mostrada en la figura 3.8 correspondiente a un modelo de regresión generalizado, sería la que se presenta en la 3.9.

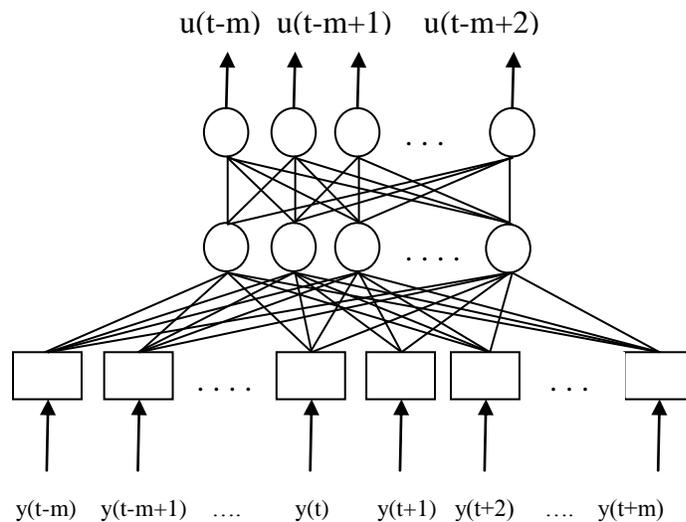


Figura 3. 9 Modelo de regresión generalizado.

3.4.5. Señales y estrategias de entrenamiento

El entrenamiento de una red neuronal que está destinada a simular un proceso dinámico, se asemeja en mucho a los experimentos que se realizan para identificar al proceso mediante métodos tradicionales aunque, como se ve, tiene algunas particularidades. Existe la posibilidad de recopilar datos históricos de entrada y salida del proceso y utilizarlos en el entrenamiento de la red, pero en este caso generalmente se requiere una muestra excesivamente grande de datos y, además; no se tiene nunca la seguridad de que se haya perturbado suficientemente al proceso y se haya recorrido toda la gama de valores posibles de las variables de entrada. Se

recomienda, por tanto, un experimento activo que consista en aplicar a la entrada del proceso una señal suficientemente perturbante como las secuencias binarias pseudo-aleatorias o simplemente una señal aleatoria con distribución uniforme con valores en el intervalo 0 – 1.

Una señal con las características mencionadas garantiza que la muestra de datos que se usa para entrenar la red, tenga una dimensión razonable. No obstante, es necesario tener en cuenta otro factor que influye notablemente en la exactitud con que la red modela al proceso dinámico. Este es el llamado “período de conmutación” de la variable de entrada, es decir, el tiempo que transcurre hasta que un nuevo valor de la variable de entrada se aplica al proceso. Experimentalmente se ha comprobado que si este valor es pequeño, entonces el modelo resultante no simula adecuadamente la ganancia del proceso, lo cual es comprensible ya que ante variaciones de la entrada muy frecuentes; la salida no puede alcanzar nunca un valor estacionario y, por tanto, la red no se entrena adecuadamente para reproducir esos estados. Este tiempo de conmutación es característico de cada proceso en particular y debe estimarse antes de comenzar el experimento de identificación. Si esto resulta difícil o costoso, debe tenerse en cuenta que es preferible que el tiempo de conmutación sea mayor del necesario y no menor.

La forma convencional de entrenar una red es acopiar una muestra de datos del proceso relativamente pequeña (500 o 1000 pares) que después es procesada fuera de línea, reciclándola varias veces (épocas de entrenamiento) hasta que se logra que los errores de predicción de la red sean suficientemente pequeños. Otra estrategia posible es el llamado entrenamiento en línea, que consiste en conectar la red al proceso en forma permanente o durante periodos prolongados y realizar el entrenamiento en tiempo real, a partir de las mediciones de entrada y salida del proceso. Esta estrategia tiene el inconveniente de que generalmente la cantidad de datos necesaria hasta lograr una convergencia aceptable puede ser excesivamente grande (varios cientos o miles).

Una estrategia combinada, consiste en un breve entrenamiento previo, a partir de datos obtenidos de un experimento que incluye el uso de señales especiales de excitación y la conexión en línea posterior de la red para seguir entrenándose con datos normales de

operación; parece ser una solución óptima, siempre que sea factible en las condiciones concretas del proceso objeto de estudio. (Aguado Behar, 2000).

El algoritmo de Backpropagation también usado es el de Levenberg-Marquardt, ya que es el tipo de entrenamiento bastante rápido y que suele ser recomendado para arquitecturas pequeñas o medianas. (Hernández López, 2006).

Actualiza los pesos según la siguiente fórmula:

$$w_{iter+1} = w_{iter} - [J^T(w_{iter}) \cdot J(w_{iter}) + \mu(w_{iter}) \cdot I]^{-1} \cdot E_T(w_{iter}) \quad 5.1$$

donde w_{iter} son los pesos de la RNA en una determinada iteración, J es la matriz Jacobiana, μ (w_{iter}) parámetro denominado de regularización, I es la matriz identidad y E_T es la función del error cuadrático medio (MSE).

3.5. Consideraciones prácticas sobre identificación

En este apartado se revisan algunas consideraciones prácticas a tener en cuenta durante el proceso de identificación.

3.5.1. Obtención de los datos

El primer paso dentro del proceso de identificación es realizar algún tipo de experimento sobre el sistema bajo estudio para obtener los datos de entrada-salida que servirán de base para la obtención del modelo final.

Para que el proceso de identificación sea satisfactorio, es necesario que los datos utilizados para tal fin contengan información significativa sobre el sistema. Esto implica un cuidadoso diseño del experimento de adquisición de datos, debiéndose tomar una serie de decisiones

respecto a las señales que deben ser medidas, el periodo de muestreo a utilizar, el tipo de entrada más adecuada, el número de datos a almacenar, etc.

3.5.1.1. Elección de las señales a medir

La primera decisión es qué señales se deben registrar (mediante algún tipo de sistema de adquisición y el correspondiente sistema de almacenamiento de datos), y qué señales deben ser manipuladas para excitar al sistema durante el experimento. Se debe tener en cuenta que pueden existir señales que, aunque afecten a la evolución de la salida, no pueden considerarse como entradas debido a la imposibilidad de actuar sobre ellas. En el caso de que estas señales puedan ser medidas, pueden considerarse también como entradas al sistema (midiéndose sus valores durante el experimento). En caso contrario, deben ser consideradas como perturbaciones.

3.5.1.2 Elección del tipo de entrada/s

La/s entrada/s al sistema deben ser cuidadosamente elegidas de forma que los datos recogidos proporcionen toda la información posible sobre el sistema. A este respecto, conviene tener en cuenta los siguientes aspectos:

- La señal de entrada debe contener el mayor número de frecuencias posibles. Por ejemplo, una señal senoidal pura no es adecuada en un experimento de identificación, puesto que sólo se obtendrá la respuesta del sistema para la frecuencia de dicha señal. Por el contrario, las señales escalonadas (con cambios bruscos) son muy utilizadas, puesto que contienen un espectro suficientemente amplio de frecuencias.
- Para muchos sistemas, basta con utilizar dos niveles de entrada, preferiblemente barriendo todo el rango de variación permitido. En este tipo de sistemas se suelen utilizar señales binarias de duración aleatoria (conocidas como señales binarias aleatorias o pseudoaleatorias), como la mostrada en la figura 3.10.

3.5.2. Pretratamiento de los datos

Los datos registrados pueden tener deficiencias que implican efectos devastadores en el resto del proceso de identificación, como son las siguientes:

- Presencia de perturbaciones de alta frecuencia, por encima de las frecuencias de interés en la respuesta del sistema.
- Datos claramente erróneos, producidos por fallos en el hardware o software utilizados en el experimento de recogida de muestras.
- Desviaciones, desplazamientos o perturbaciones de baja frecuencia.

A continuación, se verá la forma de tratar cada una de estas deficiencias para conseguir unos datos adecuados para el proceso de identificación.

3.4.2.1. Eliminación de perturbaciones de alta frecuencia

Estas perturbaciones se producen por fuentes de ruido ajenas al sistema y pueden ser evitadas mediante una correcta elección del período de muestreo. Si, tras el experimento, se observa que el período de muestreo escogido era innecesariamente pequeño (captándose por tanto estas perturbaciones indeseadas), se puede recurrir al diezmado de los datos, para evitar repetir el experimento con un período de muestreo mayor.

3.5.2.2. Eliminación de datos erróneos

Estos datos suelen presentarse de forma aislada, pero pueden tener un efecto muy negativo en el proceso de identificación. Por tanto, es fundamental eliminarlos antes de iniciar el proceso. Esto se realiza generalmente manualmente, eliminando dicho dato y aproximando su nuevo valor mediante interpolación. Para aplicaciones más avanzadas, existen algoritmos de detección de fallos que permiten corregir estos datos de forma casi automática. (López, 2006).

CAPÍTULO IV
METODOLOGÍAS PARA
EL DISEÑO DE
CONTROLARES

4.1 Introducción

Los procesos con una sola salida que son controlados por una sola variable manipulada son llamados sistemas SISO (Single-input single-output). Sin embargo, muchos procesos no se logran controlar con un controlador simple. En los procesos industriales por ejemplo, algunas operaciones unitarias capaces de fabricar o refinar algún producto no lo podrían hacer con un solo lazo de control. En efecto, cada unidad de operación típicamente requiere control en al menos dos variables, por ejemplo la velocidad de producción y la calidad del producto. Hay, por lo tanto, comúnmente dos lazos de control para cubrir este requerimiento. Los sistemas con más de un circuito de control son conocidos como sistemas MIMO (multi-input multi-output) o sistemas multivariables. Como ejemplo, considerar las siguientes operaciones unitarias de producción:

- a). Reactores químicos
- b). Columnas de destilación
- c). Intercambiadores de calor

En procesos de reacción, tal como el ejemplo mostrado en la figura 4.1, las variables de mayor interés son usualmente la mezcla o composición y la temperatura de la reacción de la masa.

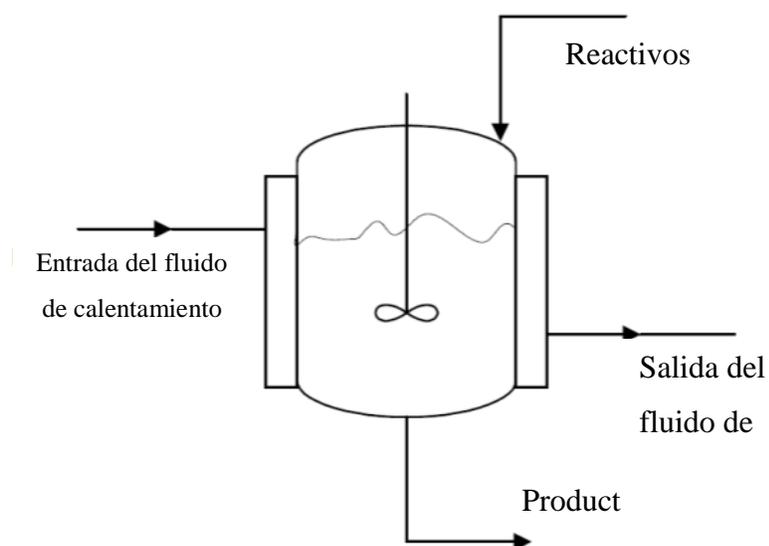


Figura 4. 1 Entrada escalonada aleatoria.

En este caso habrá un lazo de control de composición y otro de temperatura. La alimentación al reactor es normalmente usado para manipular la mezcla del producto mientras que la temperatura es controlada aumentando o disminuyendo la energía de la reacción por medio de los serpentines o camisa de calentamiento/enfriamiento. Un cambio en la alimentación, lleva a la composición a su punto de deseado y esto cambiaría la temperatura de reacción de la masa. El incremento o disminución de calor, por otro lado, determina la velocidad de reacción y consecuentemente la composición del producto. La operación de los lazos de control es en tándem, y para que puedan tener un desempeño adecuado cada lazo debe conocer lo que el otro está haciendo. De otra manera, mientras ambos lazos de control tratan de conseguir sus objetivos respectivos, podrían estar actuando en contra de los interés del otro. Este fenómeno es conocido como “Interacción de lazo”. (Tham, 1999)

4.2 Sistemas Multivariables

Para poder analizar los sistemas es importante obtener el modelo, ya sea de manera analítica: usando ecuaciones diferenciales para describir su comportamiento, o empíricamente por identificación experimental, como se mencionó en el capítulo anterior. Obviamente, el buen desempeño de de la estrategia de control depende de la exactitud del modelo. En aplicaciones donde las características físicas y/o químicas son conocidas la aproximación analítica es usualmente utilizada, por ejemplo en la industria aeroespacial donde las aeronaves, naves espaciales o misiles pueden ser adecuadamente modelados por sus ecuaciones de movimiento. En los procesos industriales, donde existe un mayor grado de incertidumbre acerca del comportamiento de los procesos, el modelado con métodos de identificación son frecuentemente utilizados.

4.3 Modelos de Sistemas Multivariables

Considerando que la muchos sistemas de varias entradas y salidas se pueden descomponer en subsistemas de 2×2 , así por simplicidad se tratará el caso de un sistema de dos entradas y dos salidas (2×2). Los modelos de varias entradas y salidas pueden asumir varias estructuras y

conexiones. Dos estructuras comunes de sistemas multivariables de 2 entradas y 2 salidas, son las representaciones canónicas P y V, éstas son mostradas en la figura 4.2.

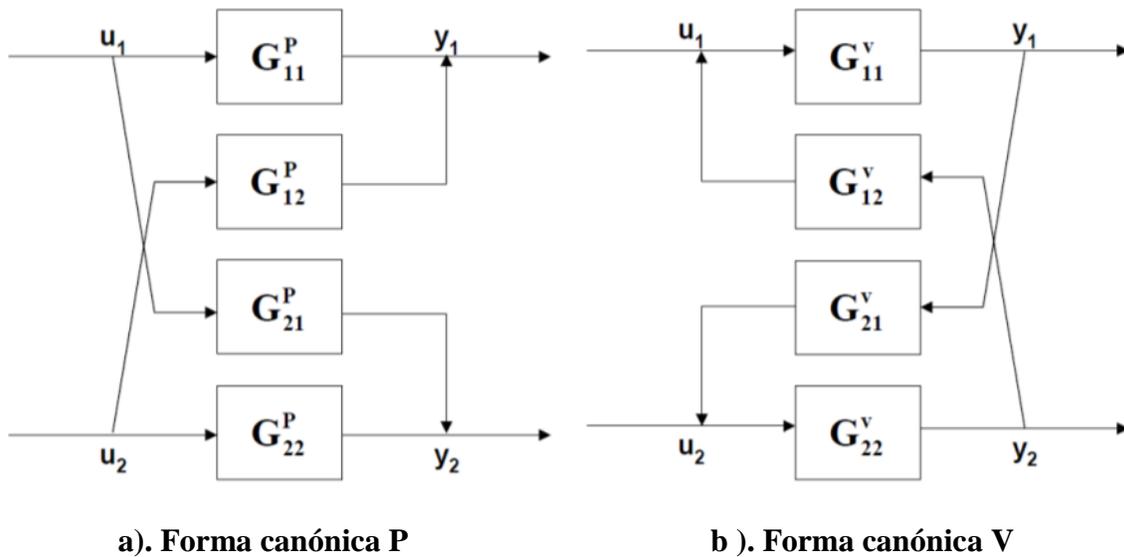


Figura 4. 2 Formas canónicas de sistemas multivariables (2x2)

En la estructura canónica P, las interacciones son consideradas como acoplamientos alimentados hacia adelante (feedforward), mientras que en la estructura canónica V las interacciones son acoplamientos retroalimentados (feedback). Los elementos en los bloques de cada diagrama son funciones de transferencia que definen la relación entre las entradas y salidas. (Tham, 1999)

4.3.1 Representación canónica P

En un lazo básico, las salidas se relacionan con las entradas de acuerdo con la siguiente relación:

$$y_1 = u_1 G_{11}^p + u_2 G_{12}^p \quad \text{ecuación 4.1}$$

$$y_2 = u_1 G_{21}^p + u_2 G_{22}^p \quad \text{ecuación 4.2}$$

Donde y_1 son las salidas del sistema mientras que u_1 son las entradas manipuladas. Las relaciones anteriores pueden ser expresadas de manera compacta utilizando vectores en una notación matricial, como:

$$y = G^p u \quad \text{ecuación 4.3}$$

$$\text{donde } y = [y_1, y_2]^T \quad y \quad u = [u_1, u_2]^T \quad \text{mientras } G^p = \begin{bmatrix} G_{11}^p & G_{12}^p \\ G_{21}^p & G_{22}^p \end{bmatrix}$$

4.3.2 Representación canónica V

Los sistemas MIMO de 2x2 tiene una representación matemática dada por:

$$y_1 = [y_2 G_{12}^v + u_1] G_{11}^v \quad \text{ecuación 4.3}$$

$$y_2 = [y_1 G_{21}^v + u_2] G_{22}^v \quad \text{ecuación 4.4}$$

O en notación vectorial-matricial:

$$y = [I - G_m^v G_i^v]^{-1} G_m^v u \quad \text{ecuación 4.5}$$

con

$$G_m^v = \begin{bmatrix} G_{11}^v & 0 \\ 0 & G_{22}^v \end{bmatrix} \quad y \quad G_i^v = \begin{bmatrix} 0 & G_{12}^v \\ G_{21}^v & 0 \end{bmatrix} \quad \text{ecuación 4.6}$$

4.3.3 Selección de tipo de estructura

Dadas las formas de modelos de los puntos anteriores, la pregunta que surge es, cuál es la mejor representación. Hay varias reglas sencillas y rápidas como guía para la sección final. Sin embargo los siguientes factores deben ser tomados en cuenta:

- a) Debe ser posible determinar los parámetros del modelo.
- b) El modelo debe ser representativo del proceso.
- c) El modelo debe ser capaz de proveer la información relevante para diseñar el sistema de control.
- d) El modelo debe ser lo más simple posible.

Considerando primeramente, la representación canónica V. No es posible obtener los elementos de la función de transferencia de las matrices G_m^v y G_i^v con la aplicación de una señal tipo escalón en lazo abierto por ejemplo. Esto se da porque un cambio en una entrada afectará no solo todas las salidas, las entradas cambiarán subsecuentemente también. Sin embargo, la relación de las funciones de transferencia para la estructura canónica V puede ser obtenida con técnicas de identificación numérica. Más aún los procesos son usualmente sujetos a factores externos, tal como cambios en el comportamiento o condiciones de operación. Estos efectos, pueden ser incorporados al modelo como términos de disturbio, en el modelo canónico V, la ecuación puede ser extendida como sigue:

$$y = [I - G_m^v G_i^v]^{-1} [G_m^v u + G_d v] \quad \text{ecuación 4.7}$$

donde $G_d = \begin{bmatrix} G_{d1} & 0 \\ 0 & G_{d2} \end{bmatrix}$ y v es un vector de los términos de disturbio, la representación en la estructura canónica P nos lleva a:

$$y = G^p u + G_d v \quad \text{ecuación 4.8}$$

Se nota que en este caso, cada par entrada-salida es definido de manera particular. La función de transferencia de G^p y G_d en la estructura canónica P puede sin embargo ser directamente determinada a partir de experimentos en lazo abierto. Una ventaja adicional de la representación canónica P es que el modelo es implícitamente observable y controlable. En otras palabras, las salidas pueden ser medidas y las entradas consideradas con relevantes para el control. Debido a que la representación canónica P supone varias ventajas es ampliamente utilizada.

Si la respuesta en estado estable de una variable controlada cambia en respuesta a una variación dada de la variable manipulada cuando los otros lazos (inicialmente abiertos) permanecen cerrados, entonces la interacción existe en el sistema. Si el controlador en cuestión fue sintonizado con los otros controladores en manual, la sintonía será incorrecta cuando éstos estén en modo automático a causa de las influencias de cada lazo en particular. Dependiendo del grado de interacción, se presentará una inestabilidad o al menos resultará un nivel de degradación.

El problema de la interacción en los lazos de control puede ser aliviado por una adecuada elección de los pares de Entrada-Salida, tal que la interacción sea disminuida.

4.3.4 Generación de la matriz de ganancias relativas

El método de la técnica de la ganancia relativa de Bristol, (Bristol, 1996), se ha constituido en una herramienta muy importante para seleccionar los pares de variable manipulada y variable controlada. El análisis, precisamente, muestra como se construye una matriz de ganancias relativas (RGA, Relative Gain Array). Para ejemplificar el concepto de ganancias relativas, RGA será construido para un sistema de (2x2) con estructura canónica.

Sea K_{ij} las ganancias de las respectivas funciones de transferencia G_{ij} . Se supone que u_2 permanece constante mientras se aplica un cambio en escalón a la entrada u_1 de magnitud Δu_1 producirá un cambio Δy_1 en la salida y_1 . Así, la ganancia entre u_1 y y_1 cuando u_2 permanece constante, está dada por:

$$K_{11}|_{u_2} = \frac{\Delta y_1}{\Delta x_1} |_{u_2} \quad \text{ecuación 4.9}$$

Si en lugar de mantener u_2 constante, y_2 es ahora mantenida constante cerrando el lazo entre y_2 y u_2 . Un cambio en escalón en la entrada u_1 de magnitud Δu_1 resultará en otro cambio en y_1 . La ganancia bajo las nuevas condiciones es ahora denotada por:

$$K_{11}|_{y_2} = \frac{\Delta y_1}{\Delta u_1} |_{y_2} \quad \text{ecuación 4.10}$$

Si bien las ganancias (ecuaciones 4.9 y 4.10) son del mismo par de variables, no obstante, pueden tener diferentes valores porque se han obtenido bajo diferentes condiciones. Si la interacción existe, entonces el cambio en y_1 debido a un cambio en u_1 para los dos casos (cuando u_2 y cuando y_2 se mantienen constantes), será diferente. La relación se expresa de la siguiente manera:

$$\lambda_{11} = \frac{K_{11}|_{u_2}}{K_{11}|_{y_2}} \quad \text{ecuación 4.11}$$

λ_{11} define la ganancia relativa entre la salida y_1 y la entrada u_1 , es adimensional. Se pueden proponer las siguientes sentencias:

- a) Si $\lambda_{11} = 0$, entonces un cambio en u_1 no influencia a y_1 , y por lo tanto no debe usarse para controlar y_1 .
- b) Si $\lambda_{11} = 1$, esto implica que $K_{11}|_{u_2}$ y $K_{11}|_{y_2}$ tienen los mismos valores. Así, por definición, la ganancia entre la salida y_1 y la entrada u_1 no es afectada por el lazo entre y_2 y u_2 , por lo tanto la interacción no existe.

Para un proceso de (2x2), hay otros tres elementos de ganancia relativa, se muestran enseguida:

$$\lambda_{12} = \frac{K_{12}|_{u_1}}{K_{12}|_{y_2}} = \frac{\left(\Delta y_1 / \Delta u_2\right)|_{u_1}}{\left(\Delta y_1 / \Delta u_2\right)|_{y_2}} \quad \text{ecuación 4.12}$$

$$\lambda_{21} = \frac{K_{21}|_{u_2}}{K_{21}|_{y_1}} = \frac{\left(\Delta y_2 / \Delta u_1\right)|_{u_2}}{\left(\Delta y_2 / \Delta u_1\right)|_{y_1}} \quad \text{ecuación 4.13}$$

$$\lambda_{22} = \frac{K_{22}|_{u_1}}{K_{22}|_{y_1}} = \frac{\left(\Delta y_2 / \Delta u_2\right)|_{u_1}}{\left(\Delta y_2 / \Delta u_2\right)|_{y_1}} \quad \text{ecuación 4.14}$$

Finalmente, la matriz de elementos λ_{ij} conforma la matriz de ganancias relativas (RGA):

$$\Lambda = \begin{bmatrix} \lambda_{11} & \lambda_{12} \\ \lambda_{21} & \lambda_{22} \end{bmatrix} \quad \text{ecuación 4.15}$$

Para un sistema general con N-entradas y N-salidas, tendrá (NxN) elementos de ganancia relativa y las ganancias relativas entre una salida y_i y una entrada u_j está dada por:

$$\lambda_{ij} = \frac{K_{y|u}}{K_{y|y}} = \frac{\left(\frac{\Delta y_i}{\Delta u_j}\right)|_u}{\left(\frac{\Delta y_i}{\Delta u_j}\right)|_y} \quad \text{ecuación 4.16}$$

Los índices u e y denotan valores constantes de $u_m, m \neq j; y_n, n \neq i$ respectivamente, y la matriz RGA para el sistema (N x N) es:

$$A = \begin{bmatrix} \lambda_{11} & \lambda_{12} & \lambda_{1N} \\ \vdots & \vdots & \vdots \\ \lambda_{N1} & \lambda_{N2} & \lambda_{NN} \end{bmatrix} \quad \text{ecuación 4.17}$$

Podría parecer que la determinación de todos los elementos de la RGA es una tarea tediosa e incómoda. En la práctica, sin embargo, esto no es así puesto que los elementos de la RGA tienen las siguientes propiedades:

- a) La suma de todos los elementos en cada columna es unitaria, esto es: $\sum_{i=1}^N \lambda_{ij} = 1$, $j=1,2,\dots, N$.
- b) La suma de todos los elementos en cada renglón es unitaria, esto es: $\sum_{j=1}^N \lambda_{ij} = 1$, $i=1,2,\dots, N$.

Así, para un sistema (2x2), la determinación de un elemento de la RGA, permite definir los otros tres, esto es:

$$\lambda_{12} = 1 - \lambda_{11}, \quad \lambda_{21} = \lambda_{12} \quad \text{y} \quad \lambda_{22} = \lambda_{11}$$

Similarmente, para un sistema (N x N), solo (N-1)*(N-1) elementos necesitan determinarse.

El método de construcción de la RGA, hace alusión a un procedimiento experimental. Una determinación analítica es posible si el modelo en estado estable del sistema está disponible.

Así, si:

$$\begin{aligned} y_1 &= K_{11}u_1 + K_{12}u_2 \quad \text{y} \\ y_2 &= K_{21}u_1 + K_{22}u_2 \end{aligned} \quad \text{ecuación 4.18}$$

donde K_{ij} son las ganancias en estado estable de la matriz de la función de transferencia del proceso. Entonces

$$K_{11}|_{u_2} = \frac{\partial y_1}{\partial u_1} |_{u_2} = K_{11} \quad \text{ecuación 4.19}$$

Eliminando u_2 de la relación de estado estable, tenemos:

$$Y_1 = K_{11}u_1 + K_{21}(y_2 - K_{21}u_1) / K_{22} \quad \text{ecuación 4.20}$$

Diferenciado con respecto a u_1 y manteniendo y_2 constante, entonces resulta:

$$K_{11}|_{y_2} = \frac{\partial y_1}{\partial u_1} |_{y_2} = K_{11} - K_{12}K_{21}/K_{22} \quad \text{ecuación 4.21}$$

La ganancia relativa λ_{11} es por tanto dada por:

$$\lambda_{11} = \frac{K_{11}|_{u_2}}{K_{11}|_{y_2}} = \frac{1}{1 - (K_{12}K_{21})/K_{11}K_{22}} \quad \text{ecuación 4.22}$$

Los elementos RGA del sistema (2x2) se calculan de forma similar.

Para un sistema general (NxN), tal que la matriz de ganancias del proceso es conocida como \mathbf{K} , entonces la RGA puede ser calculada como:

$$\Lambda = \mathbf{K} \cdot (\mathbf{K}^T)^{-1} \quad \text{ecuación 4.23}$$

Donde el operador “.” implica una multiplicación elemento por elemento.

4.3.5 Selección de los lazos de control usando la Matriz de Ganancias Relativas

Suponiendo que la matriz de ganancias relativas ha sido construida. Los siguientes casos se pueden presentar:

- a) Si $\lambda_{11}=0$, entonces la RGA tiene ceros en los elementos de diagonal y unos en los elementos fuera de la diagonal. Esto indica que el control de sistema puede solo ser logrado por los pares y_1 con u_2 , y y_2 con u_1 . El sistema controlado resultante, sin embargo, será no-interactuante.
- b) Si $\lambda_{11}=1$, entonces el sistema es no-interactuante con los pares y_1-u_1 y y_2-u_2 . Por lo mismo, u_1 no puede ser usado para controlar y_2 , ni puede u_2 ser usado para controlar y_1 porque las entradas no tienen efecto en las respectivas salidas.
- c) Si $\lambda_{11}=0.5$, entonces las dos entradas manipuladas afectan a las dos salidas en la misma medida. Esto refleja el peor caso de todos los aparejamientos, el grado de interacción será el mismo.
- d) Si $0 < \lambda_{11} < 0.5$ ($\lambda_{11} = 0.25$ por ejemplo), entonces los elementos de la diagonal de la RGA es igual a 0.25 mientras que los elementos fuera de la diagonal serán 0.75. Los elementos mayores indican la mejor elección de pares entrada-salida, por lo tanto las parejas quedan y_1 con u_2 , y y_2 con u_1 .
- e) Si $0.5 < \lambda_{11} < 1$ ($\lambda_{11} = 0.75$ por ejemplo), entonces tenemos el caso opuesto al del inciso d) y las mejores parejas serán y_1-u_1 y y_2-u_2 .
- f) Si $\lambda_{11} > 1$, entonces los elementos fuera de la diagonal de la RGA serán negativos. Si los pares y_1-u_1 y y_2-u_2 son empleados, las correspondientes ganancias relativas son por lo tanto mayores que uno. Por definición se tiene la siguiente implicación:

$$\lambda_{11} = \frac{K_{11}|u_2}{K_{11}|y_2} > 1 \quad \text{y} \quad \lambda_{22} = \frac{K_{22}|u_1}{K_{22}|y_1} > 1 \quad \text{ecuación 4.24}$$

Si se supone $K_{11}|u_2 = 1$, entonces para $\lambda_{11} > 1$, $0 < K_{11}|y_2 < 1$. Lo cual quiere decir que el cambio en y_1 debido a un cambio en u_1 es reducido si el lazo entre y_2 y u_2 está cerrado. En otras palabras, las respuestas controladas serán mantenidas bajas por la interacción del otro lazo. La ganancia relativa mayor está arriba de uno, y su efecto será el mayor. Los pares alternos y_1 con u_2 , y y_2 con u_1 son, sin embargo, es inadecuado porque las correspondientes ganancias son negativas. Esto quiere decir que las interacciones tomarán efecto en las salidas de control en una dirección lejana al objetivo que dicho controlador esté tratando de alcanzar. Como resultado se tendrá que el control eventualmente se perderá.

Los casos antes mencionados, junto con las correspondientes reglas para la selección de entradas-salidas, está lejos de completarse. Un riguroso análisis podría incluir sistemas donde hubiera más entradas que salidas, por ejemplo, la presencia de perturbaciones. Las señales de las ganancias de los procesos son también importantes factores en el análisis de RGA. Como complemento al análisis presentado, se presenta una regla general para la selección de lazos de control:

“Los lazos de control deben tener pares de entrada-salida con ganancia relativa positiva con valores tan cercanos a la unidad como sea posible” (Tham, 1999).

El uso de las ganancias relativas para determinar las mejores parejas de entrada (variable manipulada)-Salida (Variable controlada) para controladores multivariables lleva a determinar una estrategia de control de interacción dominante.

4.3.6 Técnicas de desacoplamiento de sistemas

4.3.6.1 Conexiones feed-forward

El control mediante conexiones feed-forward o anticipativas está concebido como una forma de mejorar la capacidad de la regulación de variables sometidas a fuertes perturbaciones o también cuando existen fuertes interconexiones entre diversos lazos de control de un mismo proceso tecnológico. Como su nombre lo indica, la conexión feed-forward trata de anticiparse al efecto que sobre una variable determinada tiene la variación de una perturbación que puede medirse o la variación de otra variable de control, distinta a la utilizada propiamente en el lazo. La anticipación se logra actuando inmediatamente sobre la válvula o elemento de acción final del lazo, antes que se produzca una desviación de la variable controlada. Las conexiones feed-forward constituyen un complemento de regulación normal por feed-back y no un sustituto de ésta. Antes del surgimiento y popularización del control digital eran raramente usadas, debido al costo adicional requerido y a la falta de flexibilidad del equipamiento analógico. En la actualidad, no obstante, el control por computadoras permite la inclusión de conexiones feed-forward sin un incremento considerable en el costo (solo el de las mediciones

adicionales requeridas) y con un grado de flexibilidad mucho mayor. En el diagrama de la figura 4.3 se representa una conexión Feed-Forward dentro de un lazo de control simple.

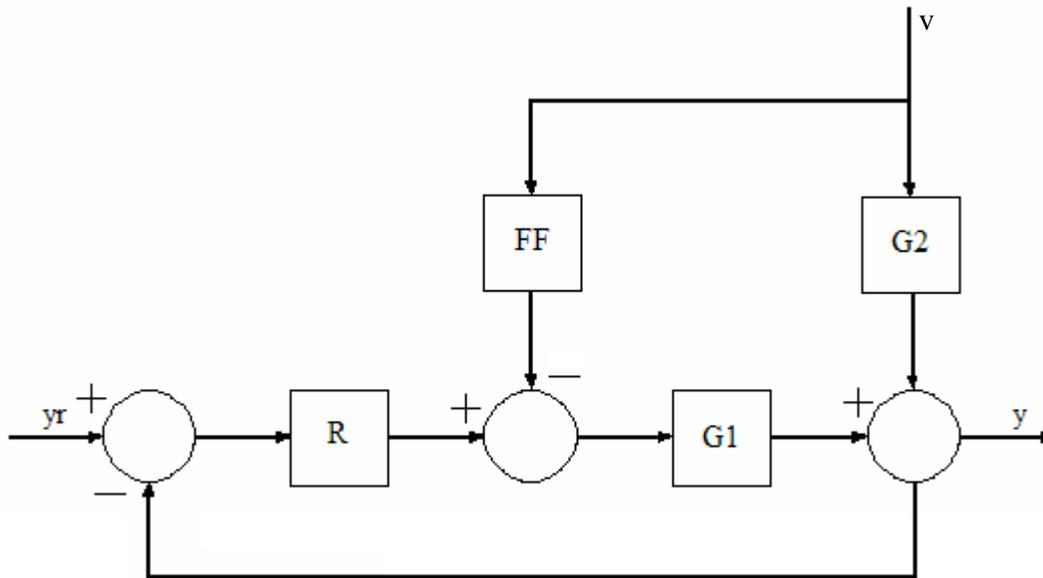


Figura 4. 3 Conexión Feed-Forward en lazo de control simple.

$$\frac{\Delta y}{\Delta v} = \frac{G_2(z^{-1})}{1 + RG_1(z^{-1})} + \frac{FFG_1(z^{-1})}{1 + RG_1(z^{-1})} = 0 \quad \text{ecuación 4.25}$$

$$\frac{\Delta y}{\Delta v} = \frac{G_2(z^{-1}) + FFG_1(z^{-1})}{1 + RG_1(z^{-1})} \quad \text{ecuación 4.26}$$

$$FF = - \frac{G_2(z^{-1})}{G_1(z^{-1})} \quad \text{ecuación 4.27}$$

Si se aproximan $G_1(z^{-1})$ y $G_2(z^{-1})$ como dos funciones transferenciales de 1er orden con retardo:

$$G_1(z^{-1}) = \frac{K_1 z^{-p1}}{1 - \alpha_1 z^{-1}} \quad \text{ecuación 4.28}$$

$$G_2(z^{-1}) = \frac{K_2 z^{-p2}}{1 - \alpha_2 z^{-1}} \quad \text{ecuación 4.29}$$

Entonces:

$$FF(z^{-1}) = \frac{K_2 z^{-p_2} (1 - \alpha_1 z^{-1})}{K_1 z^{-p_1} (1 - \alpha_2 z^{-1})} \quad \text{ecuación 4.30}$$

Donde:

$$\alpha_1 = e^{-T_s/T_1} \quad \alpha_2 = e^{-T_s/T_2} \quad \text{ecuación 4.31}$$

Finalmente:

$$\frac{\Delta u}{\Delta v} = FF(z^{-1}) = -K_{FF} Z^{(p_1 - p_2)} \frac{1 - \alpha_1 z^{-1}}{1 - \alpha_2 z^{-1}} \quad \text{ecuación 4.32}$$

$$K_{FF} = \frac{K_2}{K_1} \quad \text{ecuación 4.33}$$

En muchas ocasiones es suficiente solo una compensación del valor estacionario y entonces se hace $FF = K_{FF}$.

Si se utiliza una compensación dinámica, tal como se expresa mediante (4.32), entonces hay que tomar en consideración la siguiente condición:

Para que la compensación tenga un sentido real es necesario que $p_1 \leq p_2$, es decir, el retardo en el canal principal debe ser menor o igual que el retardo en el canal de la perturbación, pues de otra manera habría que utilizar predicciones de valores futuros de la perturbación. Esto se comprende mejor observando la ecuación de diferencia asociada:

$$\Delta u (1 - \alpha_2 z^{-1}) = -K_{FF} Z^{(p_1 - p_2)} (1 - \alpha_1 z^{-1}) \Delta v \quad \text{ecuación 4.34}$$

$$\Delta u(t) = -K_{FF} \Delta v(t + p_1 - p_2) + \alpha_1 K_{FF} \Delta v(t + p_1 - p_2 - 1) + \alpha_2 \Delta v(t - 1) \quad \text{ecuación 4.35}$$

Resulta claro que si $p_1 - p_2 > 0$ entonces se requieren valores futuros o predicciones de Δv en el tiempo t .

La compensación feed-forward pueden utilizarse para desacoplar lazos simples fuertemente acoplados. En la figura 4.4 se muestra un ejemplo de esta situación. Este tipo de desacople puede sustituir en buena medida, otro tipo de solución como el diseño de reguladores multivariables que es mucho más compleja y de resultados muchas veces imprevisible.

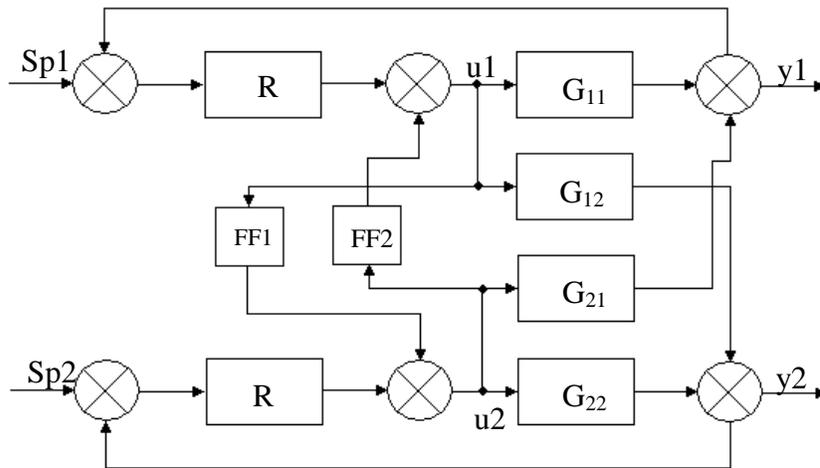


Figura 4. 4 Conexión Feed-Forward compensado para desacoplar dos lazos.

$$FF1 = - \frac{G_{12}}{G_{22}} \quad \text{ecuación 4.35}$$

$$FF2 = - \frac{G_{21}}{G_{11}} \quad \text{ecuación 4.36}$$

Donde R_1 y R_2 son controladores PID. (Aguado Behar, 2000).

Una alternativa la presenta Goerge Stephanopoulos (Stephanopoulos, 1984) y plantea un desacoplamiento completo, que para encontrar la función de transferencia del desacoplador debe cumplirse:

- Una variación en la señal de entrada Sp_1 no debe influir en y_2 .
- La influencia de la transmitancia G_{12} sobre y_2 se compensa mediante la función de transferencia FF_1 que enlaza u_2 con Sp_1 .
- Una variación en la señal de entrada sp_2 no debe provocar ninguna reacción en y_1 .

Con un correcto desacoplamiento, el control multivariable pasa al de la figura 4.5. Los parámetros pueden identificarse por cálculo de las funciones de transferencia, o bien del modo siguiente: se mantiene sp_2 constante y se varía sp_1 y se registra el valor de y_1 de donde se

deducen los parámetros del proceso + desacoplador 1. Análogamente se procede con la entrada sp_1 .

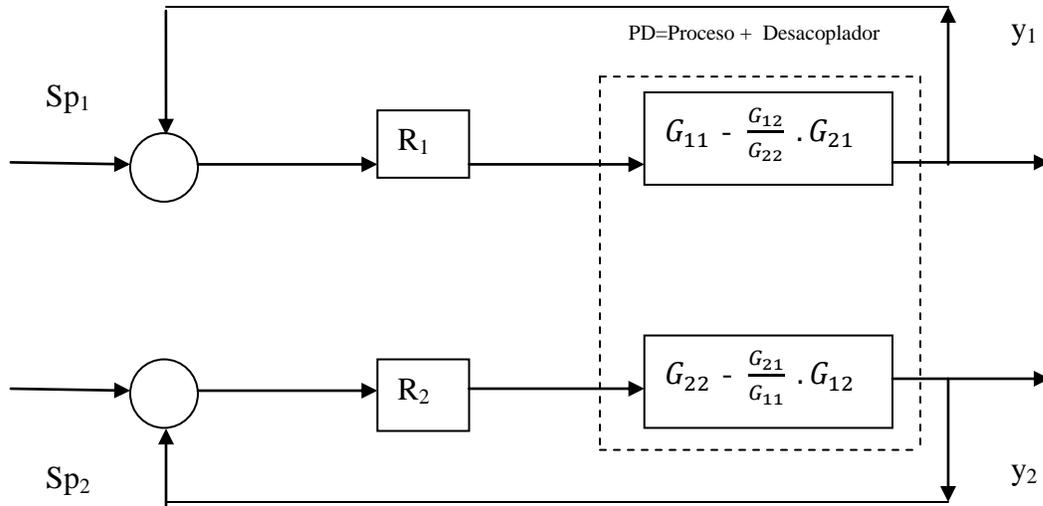


Figura 4. 5 Diagrama equivalente con desacoplador

$$PD1 = G11 - \frac{G21}{G22} \cdot G12 \quad (4.37)$$

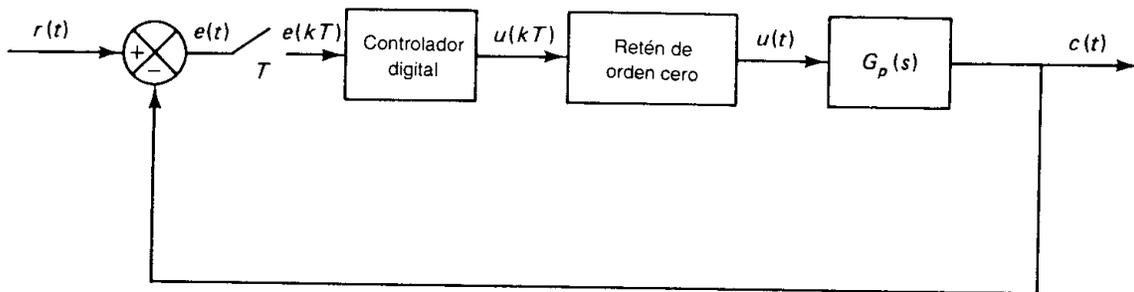
$$PD2 = G22 - \frac{G12}{G11} \cdot G21 \quad (4.38)$$

4.4 Método de diseño analítico para sistemas en tiempo discreto

4.4.1 Diseño de controladores digitales para un tiempo de asentamiento mínimo con un error cero en estado permanente

Considerando el sistema de control digital que se muestra en la figura 4.6. La señal de error $e(t)$, que es la diferencia entre la entrada $r(t)$ y la salida $c(t)$, se muestrea en cada intervalo de

tiempo T . La entrada al controlador digital es la señal de error de $e(kT)$. La salida del controlador digital es la señal de control $u(kT)$. La señal de control $u(kT)$ es alimentada al retén de orden cero, y la salida del retén, $u(t)$, que es una señal en tiempo continuo, es alimentada a la planta. (A pesar de que no se muestra el dispositivo de muestreo en la entrada del retén de orden cero, la señal $u(kT)$ es primero muestreada y alimentada al retén de orden cero. El retén de orden cero que se muestra en el diagrama es un muestreador y retén).



a)

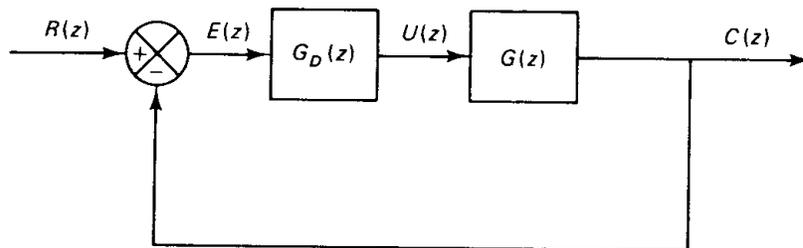


Figura 4. 6 a) Un sistema de control digital. b) Diagrama de control equivalente.

Se desea diseñar un controlador digital $G_D(z)$ tal que el sistema de control en lazo cerrado muestre el tiempo de asentamiento mínimo posible, con un error en estado permanente cero, en respuesta a una entrada escalón, rampa o de aceleración. Se requiere que la salida no presente componentes oscilatorias entre muestras, después de haber alcanzado el estado permanente. Si se requiere, el sistema deberá satisfacer cualquier otra especificación, como es la correspondiente a la constante de error de velocidad estática.

Se define la transformada de z de la planta, precedida por el retén de orden cero, como $G(z)$, es decir

$$G(z) = z \left[\frac{1 - e^{-Ts}}{s} G_p(s) \right] \quad \text{ecuación 4.36}$$

Entonces, la función de transferencia pulso en lazo abierto se convierte en $G_D(z)G(z)$, tal como se muestra en la figura 4.6b. A continuación se define la función de transferencia pulso en lazo cerrado deseado como $F(z)$:

$$\frac{C(z)}{R(z)} = \frac{G_D(z)G(z)}{1 + G_D(z)G(z)} = F(z) \quad \text{ecuación 4.37}$$

Dado que es necesario que el sistema tenga un tiempo de asentamiento finito con un error en estado permanente cero, el sistema deberá mostrar una respuesta impulso finita. Por lo tanto, la función de transferencia pulso en lazo cerrado deseado debe ser de la forma siguiente:

$$F(z) = \frac{a_0 z^N + a_1 z^{N-1} + \dots + a_N}{z^N} \quad \text{ecuación 4.38}$$

Es decir

$$F(z) = a_0 + a_1 z^{-1} + \dots + a_N z^{-N} \quad \text{ecuación 4.39}$$

Donde $N \geq n$, y n es el orden del sistema. (Se debe notar que $F(z)$ no debe contener ningún término con potencias positivas en z , ya que dichos términos en la expansión en series de $F(z)$ implicarían que la salida antecede a la entrada, lo que no es posible para un sistema físicamente realizable.) En este método de diseño (Ogata, 1996) se resuelve la función de transferencia pulso en lazo cerrado para la función de transferencia pulso del controlador digital $G_D(z)$. Esto es, se busca que la función de transferencia pulso $R(z)$ satisfaga la ecuación 4.37 en función de $G_D(z)$ obtenemos

$$G_D(z) = \frac{F(z)}{G(z)[1 - F(z)]} \quad \text{ecuación 4.40}$$

El sistema diseñado debe ser físicamente realizable. Las condiciones para que esto ocurra imponen ciertas limitantes a la función de transferencia pulso en lazo cerrado $F(z)$ y en la función de transferencia pulso del controlador digital $G_D(z)$. Las condiciones para que sean físicamente realizables pueden enunciarse como sigue:

1. El grado del numerador $G_D(z)$ debe ser igual o menor que el grado del denominador. (De no ser así, el controlador requiere que sean datos de entrada futuros los que produzcan la salida de corriente).
2. Si la planta $G_p(s)$ incluye un atraso de transporte e^{Ls} , entonces el sistema en lazo cerrado diseñado debe involucrar por lo menos la misma magnitud de atraso de transporte. (De no ser así, el sistema en lazo cerrado tendría que responder antes de que se le diera una entrada, lo que es imposible realizar en un sistema físico).
3. Si $G(z)$ se expande a una serie en z^{-1} , el término elevado a la potencia menor de la expansión serial de $F(z)$ en z^{-1} debe ser por lo menos igual de grande que el correspondiente a $G(z)$. Por ejemplo, si la expansión de $G(z)$ en una serie en z^{-1} empieza con el término z^{-1} , entonces el primer término de $F(z)$ dado por la ecuación 4.39. deberá ser cero, o a_0 debe ser igual a 0, esto es, la expansión deberá ser de la forma

$$F(z) = a_1 z^{-1} + a_2 z^{-2} + \dots + a_N z^{-N} \quad \text{ecuación 4.41}$$

Donde $N \geq n$, y n es el orden del sistema. Esto significa que la planta no puede responder en forma instantánea cuando es aplicada una señal de control de magnitud finita; la respuesta se presenta con un atraso de por lo menos un período de muestreo, si la expansión de la serie de $G(z)$ empieza con un término z^{-1} .

Además de las condiciones de la posibilidad física de realización, tenemos que poner atención en aspectos de estabilidad del sistema. De manera específica, se debe evitar la cancelación de un polo inestable de la planta mediante un cero del controlador digital. Si se intenta es tipo de cancelación, cualquier error en la cancelación entre polos y ceros generará una divergencia conforme pasa el tiempo y el sistema se hará inestable. En forma similar, la función de

transferencia pulso del controlador digital no deberá incluir polos inestables para cancelar cero de la planta que ocurran fuera del círculo unitario.

Ahora se investigará lo que ocurrirá con la función de transferencia pulso en lazo cerrado $F(z)$ si $G(z)$ incluye un polo inestable (o críticamente estable), esto es, un polo $z=\alpha$ exterior al círculo unitario o bien sobre él. Este análisis aplica de la misma manera, si $G(z)$ incluye dos polos o más inestables, o críticamente estables. Se define

$$G(z) = \frac{G_1(z)}{z - \alpha} \quad \text{ecuación 4.42}$$

Donde $G_1(z)$ no incluye un término que se cancele con $z-\alpha$. Entonces la función de transferencia pulso en lazo cerrado se convierte en

$$\frac{C(z)}{R(z)} = \frac{G_D(z)G(z)}{1 + G_D(z)G(z)} = \frac{G_D(z) \frac{G_1(z)}{z - \alpha}}{1 + G_D(z) \frac{G_1(z)}{z - \alpha}} = F(z) \quad \text{ecuación 4.43}$$

En vista de que requerimos que ningún cero de $G_D(z)$ cancele el polo inestable de $G(z)$ en $z=\alpha$, se debe tener

$$1 - F(z) = \frac{1}{1 + G_D(z) \frac{G_1(z)}{z - \alpha}} = \frac{z - \alpha}{z - \alpha + G_D(z)G_1(z)} \quad \text{ecuación 4.44}$$

Esto es, $1-F(z)$ debe tener como cero a $z= \alpha$. También, se nota de la ecuación 4.43 si cero de $G(z)$ no cancelan polos de $G_D(z)$, los ceros de $G(z)$ se convierten en ceros de $F(z)$. [$F(z)$ puede incluir ceros adicionales].

En resumen lo referente a la estabilidad se puede expresar como sigue:

1. Dado que el controlador digital $G_D(z)$ no debe cancelar los polos inestables (o críticamente estables) de $G(z)$, todos los polos inestables (o críticamente estables) de $G(z)$ deberán incluirse en $1-F(z)$ como ceros.
2. Los ceros de $G(z)$ que se presenten dentro del círculo unitario pueden cancelarse con polos de $G_D(z)$. Sin embargo, los ceros de $G(z)$, que ocurran sobre o fuera del círculo unitario, no deben cancelarse con polos de $G_D(z)$. Por lo tanto, todos los ceros de $G(z)$ que se presenten sobre o por fuera del círculo unitario deberán ser incluidos en $F(z)$ como ceros.

Ahora, continuando con el diseño. Dado que $e(kT)=r(kT)-c(kT)$, refiriéndonos a la ecuación 4.37 tenemos

$$E(z) = R(z) - C(z) = R(z)[1 - F(z)] \quad \text{ecuación 4.45}$$

Se nota que para una entrada escalón unitario $r(t)=1(t)$

$$R(z) = \frac{1}{1 - z^{-1}} \quad \text{ecuación 4.46}$$

Para una entrada rampa unitaria $r(t)=t1(t)$,

$$R(z) = \frac{Tz^{-1}}{(1 - z^{-1})^2} \quad \text{ecuación 4.47}$$

Y para entrada de aceleración unitaria $r(t) = \frac{1}{2}r^2 1(t)$,

$$R(z) = \frac{T^2 z^{-1}(1 + z^{-1})}{2(1 - z^{-1})^3} \quad \text{ecuación 4.48}$$

Por lo tanto, en general, las transformadas z en estas entradas polinomiales en el dominio de tiempo se pueden escribir como

$$R(z) = \frac{P(z)}{(1 - z^{-1})^{q+1}} \quad \text{ecuación 4.49}$$

Donde $P(z)$ es un polinomio en z^{-1} . Se nota que para una entrada escalón unitario, $P(z)=1$ y $q=0$; para una entrada rampa unitaria, $P(z)=Tz^{-1}$ y $q=1$; y para una entrada de aceleración unitaria, $P(z)=\frac{1}{2}T^2z^{-1}(1 + z^{-1})$ y $q=2$.

Al sustituir la ecuación 4.49 en la ecuación 4.45 obtenemos

$$E(z) = \frac{P(z)[1 - F(z)]}{(1 - z^{-1})^{q+1}} \quad \text{ecuación 4.50}$$

Para asegurar que el sistema llega al estado permanente en un número finito de períodos de muestreo y mantiene un error cero en estado permanente, $E(z)$ deberá ser un polinomio en z^{-1} con un número finito de términos. Entonces, refiriéndonos a la ecuación 4.50, se escoge la función $1-F(z)$ con la forma

$$1 - F(z) = (1 - z^{-1})^{q+1} N(z) \quad \text{ecuación 4.51}$$

Donde $N(z)$ es un polinomio en z^{-1} con un número finito de términos. Entonces

$$E(z) = P(z)N(z) \quad \text{ecuación 4.52}$$

Que es un polinomio en z^{-1} con un número finito de términos. Esto significa que la señal de error se convierte en cero en un número finito de períodos de muestreo.

Del análisis anterior, la función de transferencia pulso del controlador digital puede determinarse como sigue. Si se supone primero que $F(z)$ satisface la posibilidad física de realización y las condiciones de estabilidad, y a continuación se sustituye la ecuación 4.51 en la ecuación 4.40,

$$G_D(z) = \frac{F(z)}{G(z)(1 - z^{-1})^{q+1} N(z)} \quad \text{ecuación 4.53}$$

La ecuación 4.53 da la función de transferencia pulso del controlador digital que producirá un error cero en estado permanente, después de un número finito de períodos de muestreo.

Para una planta estable $G_p(s)$, la condición para que la salida no muestre componentes oscilatorios entre muestreos después del tiempo de asentamiento, se puede escribir como sigue:

$c(t \geq nT) = \text{constante}$, para entradas escalón

$\dot{c}(t \geq nT) = \text{constante}$, para entradas rampa

$\ddot{c}(t \geq nT) = \text{constante}$, para entradas de aceleración

La condición aplicable deberá ser satisfecha cuando se diseñe el sistema. Al diseñar el sistema, la condición sobre $c(t)$, $\dot{c}(t)$ o $\ddot{c}(t)$ deberá de interpretarse en términos de $u(t)$. Se nota que la planta está en tiempo continuo y la entrada a la planta es $u(t)$, que es una función en tiempo continuo; por lo tanto, para no tener componentes oscilatorias en la salida $c(t)$, la señal de control $u(t)$ en estado permanente debe ser constante o de un incremento monótono (o

decrementándose monótonamente) para los casos de entrada escalón, rampa y de aceleración. (Ogata, 1996).

4.5 Control Predictivo basado en Modelos (CPBM)

El Control Predictivo Basado en Modelos (CPBM) o en Inglés "Model Predictive Control" (MPC), se considera dentro de los controladores óptimos, en otras palabras, en los que las acciones de control se calculan mediante la optimización de un criterio o función que se encuentra en relación con el comportamiento futuro del sistema, mismo que se predice con un modelo dinámico previamente diseñado, por ello se dice que este controlador está basado en modelos.

El control predictivo presenta ventajas sobre otro tipo de controladores, entre las que se pueden citar las siguientes (Camacho, 2004):

- es una técnica particularmente atractiva para los operadores que requiere pocos reconocimientos de control porque los conceptos son muy intuitivos y la sintonización es relativamente simple,
- se puede utilizar para controlar una gran variedad de procesos, desde procesos muy simples hasta procesos con dinámicas complejas como procesos con grandes tiempos muertos, procesos inestables o procesos multivariados,
- su carácter predictivo lo hace compensar intrínsecamente los tiempos muertos,
- introduce un control anticipativo (feedforward) y de forma natural se compensan las perturbaciones medibles,
- la ley de control resultante es en general fácilmente implementable,
- es muy útil cuando se conocen las referencias futuras, como ocurre en el caso de robótica o procesos por lotes.
- permite tratar las restricciones de una forma sistemática y conceptualmente muy simple durante las fase de diseño.

Este tipo de controladores también presenta ciertos inconvenientes asociados a su implementación y los cálculos a realizar ante restricciones y procesos rápidos, pero debido a la

potencia de los procesadores actuales esta dificultad se puede solventar de manera conveniente.

Una de las propiedades más atractivas del CPBM es su formación abierta, es decir, permite considerar diferentes tipos de modelos de predicción, así como restricciones, lo cual ha logrado un impacto importante en el ámbito industrial (Qin S. T., 1997). De hecho el control predictivo se formuló inicialmente en el ámbito industrial, pero ha sido en el ámbito académico donde se le ha dado una base teórica (Qin S. J., 2003).

4.5.1 Conceptos básicos del CPBM

El Control Predictivo Basado en Modelos más que un controlador concreto es una metodología para el cálculo de las acciones de control. Se trata además de una metodología comprensible, que en cierta forma trata de reproducir la forma de actuar que tendría un operador experto en el control de un determinado proceso (Ramos Fernández, 2007). Los pasos que seguiría un operador experto para conseguir controlar un proceso serían:

1. El operador conoce bien el proceso (posee un modelo mental del mismo) y por tanto, sería capaz de **predecir** con mayor o menor exactitud cuál será la evolución dinámica de las variables del proceso si se aplican unas acciones de control determinadas. En ese sentido, el CPBM reproduce dicho aspecto, haciendo uso explícito de un **modelo** del proceso para el cálculo de **predicciones** de la evolución dinámica del mismo.
2. El mismo operador puede además, decidir si esa evolución es adecuada en comparación a los objetivos que se ha marcado. Es capaz por tanto de valorar las distintas combinaciones de las acciones de control en un horizonte de tiempo (**ley de control**) en función del grado de cumplimiento de unas especificaciones. El CPBM también compara el cumplimiento de las especificaciones, de modo cuantitativo, mediante el uso de una función de coste o **criterio de optimización**.
3. Con todo esto, podrá decidir cuál es la mejor combinación de acciones de control dentro de un conjunto de posibilidades. El resultado final es que el operador es capaz de obtener cuál debe ser la combinación de acciones de control y la información del estado pasado y actual del mismo. Del mismo modo, del CPBM obtiene la ley de control mediante la **minimización** de la

función de optimización (función de coste), en la que interviene información pasada y actual del estado del proceso.

4. Para conseguir una mayor calidad en el control, este mismo operador repetiría todos los cálculos cada vez que disponga de información actualizada, bien sean nuevas medidas del estado del proceso, bien conocimientos actualizados acerca del comportamiento del proceso (información nueva del modelo). En el CPBM, a este concepto se le denomina **horizonte móvil** o "reciding horizon", resultando en la resolución de un problema de optimización (minimización) diferente en cada **periodo de muestreo**, puesto que se incorpora nueva información de la evolución dinámica del proceso.

En la figura 4.7 se pueden ver de forma gráfica los conceptos propuestos anteriormente.

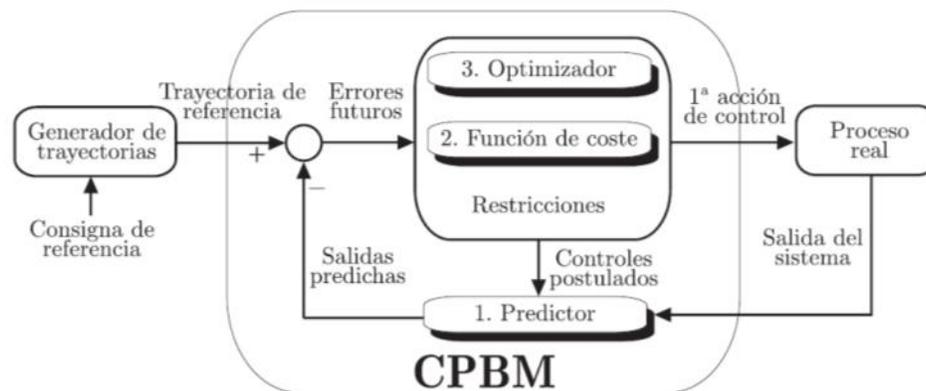


Figura 4. 7 Control Predictivo Basado en Modelos.

a) Predictor. Basado en el modelo del proceso es el encargado de calcular, para cada instante t , las predicciones de la evolución dinámica del proceso $[y(t+1|t), \dots, y(t+N|t)]$, a lo largo del horizonte de predicción N , a partir de la información dinámica que se dispone hasta ese instante (medidas de las variable del proceso y entradas pasadas hasta el instante actual t) y una ley de control postulada o futura $[u(t|t), \dots, u(t+N|t)]$, a lo largo del horizonte de predicción, tal y como se muestra en la figura 4.8. La sintaxis $y(t+k|t)$ se utiliza para indicar la predicción de la salida para el instante $t+k$ postulada en el instante t .

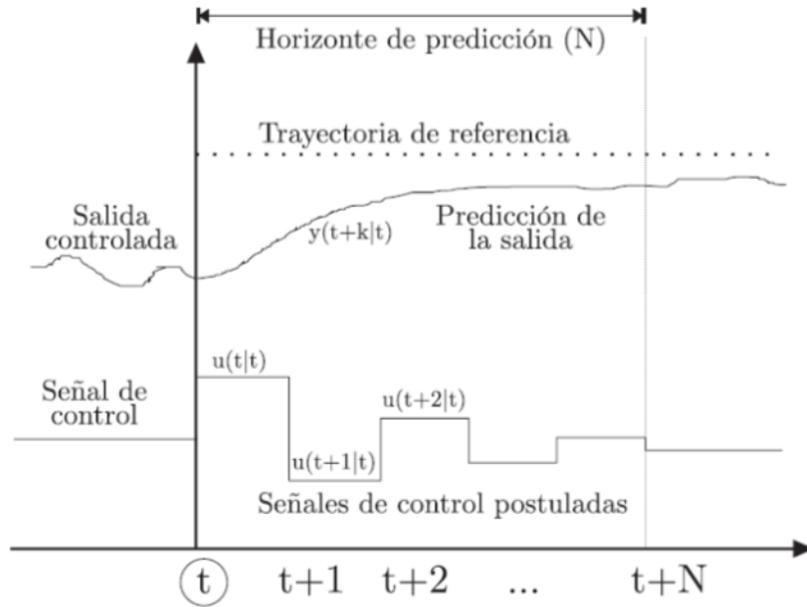


Figura 4. 8 Predicción de la salida y señal de control postulada.

b) Criterio de optimización o función de coste. Las futuras acciones de control se calculan de manera que minimicen un determinado criterio de optimización. Así pues, el criterio de optimización asigna un valor a cada predicción y por tanto a cada ley de control postulada. Este valor trata de mostrar el grado de cumplimiento de las especificaciones estáticas y dinámicas compatibles con las posibles restricciones de funcionamiento. Por ello, el objetivo principal del criterio de optimización consiste en mantener la salida del proceso $y(t+k|t)$ lo más cerca posible de una trayectoria de referencia $w(t+k)$ que describe cómo se desea guiar dicha salida desde su valor actual $y(t)$ hasta sus puntos deseados futuros. El criterio de optimización adopta así generalmente la forma de una función **cuadrática** de los errores entre la salida predicha y la trayectoria de referencia. También en la mayoría de los casos suele incluir algún término referente al esfuerzo de control.

c) Optimizador. Debe encontrar el vector de acciones de control que ofrece el mejor valor del criterio de optimización. Generalmente en este proceso de búsqueda, el optimizador realiza postulados de la ley de control e iterativamente trata de acercarse a la **ley de control óptima**. Además, si el criterio de optimización propuesto es cuadrático, el modelo utilizado es lineal y no existen restricciones para ninguna señal implicada, entonces es posible encontrar una

solución analítica para el problema de optimización. En caso contrario, es necesario utilizar, en general, un método numérico de optimización.

d) Horizonte móvil. Una vez calculada la secuencia de futuras acciones de control que en ese instante hacen óptima la función de coste, se hace uso del concepto denominado "receding horizon". Solamente se aplica como entrada al proceso $u(t|t)$ la primera de ellas, despreciando el resto, puesto que en el siguiente instante $t+1$, la salida $y(t+1)$ ya es conocida, y con esa nueva información se repiten los puntos a, b, y c obteniendo de esta forma la señal de control $u(t+1|t+1)$ a aplicar en ese instante (la cual no es igual a la que se había postulado en el instante anterior $u(t+1|t)$).

El análisis de esta metodología de control muestra que, sea cual sea la implementación que se realice, cualquier control predictivo basado en modelos se puede entender como un problema de optimización en cada periodo de muestreo (horizonte móvil) que consta de tres elementos fundamentales: predictor, función de coste y optimizador.

Combinando distintas variaciones de estos tres elementos fundamentales se pueden obtener un gran número de controladores que formarán parte de la familia de los controladores predictivos (Ramos Fernández, 2007).

4.5.1.1 Predictor

Para calcular las predicciones de la evolución dinámica de las variables que se quieren controlar se debe utilizar un modelo. En general este modelo consta de dos componentes, figura 4.9:

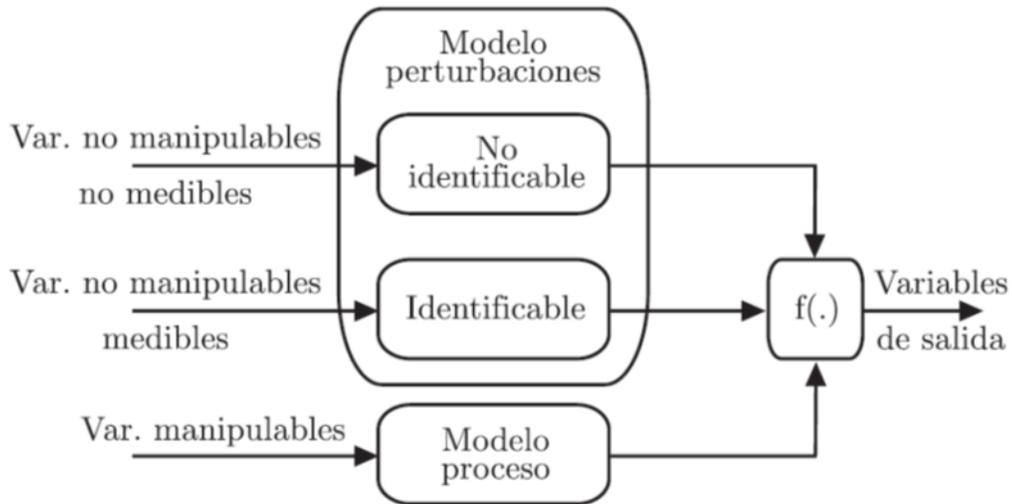


Figura 4. 9 Estructura general de un modelo.

1. Modelo del proceso que relaciona todas las variables de entrada que se pueden manipular con las variables de salida que se quieren controlar.

2. Modelo de perturbaciones: se puede dividir en dos partes. Una que incluye la relación entre variables de entrada que se pueden medir pero no manipular, con las salidas (modelo de perturbaciones identificable); y otra parte que trata de describir la parte de la salida medida que no es explicada por el resto de modelos (modelo de perturbaciones no identificable).

Estos modelos se combinan a través de una función $f(\cdot)$ para producir un modelo de las variables de salida.

Para modelar cada uno de estos componentes existen varias posibilidades. Las diferencias entre los distintos tipos de modelos son conocidas y son objeto de estudios en los que se describe cómo se obtienen, qué tipo de procesos pueden modelar, cuáles son sus limitaciones y cómo se utilizan para realizar predicciones de la evolución dinámica de las variables de un proceso.

La calidad de la predicción es un factor que determina el tipo de técnica de modelado que se debe utilizar, al menos a nivel teórico. Es natural pensar que a mayor calidad en las predicciones más posibilidades se tienen de obtener un control adecuado. En las aplicaciones prácticas aparecen otros factores como los económicos que pueden determinar, más allá de cuestiones teóricas, el tipo de modelo seleccionado.

Cuando se tienen variables no manipulables no se puede saber con certeza qué valores van a tomar en el futuro y por tanto en el horizonte de predicción (intervalo de tiempo en el que se quiere realizar la predicción). El modelo puede ser muy exacto, pero el desconocimiento del valor futuro de estas variables podría producir predicciones de muy baja calidad. En estos casos se debe, al menos, conocer alguna de sus propiedades estadísticas que nos permita realizar una estimación. Si estas variables son medibles se pueden utilizar las medidas para realizar unas estimaciones de mayor calidad (por ejemplo, evaluar la tendencia y extrapolar). La calidad de la predicción, en estos casos, depende tanto de la calidad del modelo como de la calidad de las estimaciones que se realizan de las variables no manipulables.

Para tratar de compensar la dinámica no modelada se añaden al modelo elementos artificiales en su estructura para tratar de incrementar la calidad del control. Por ejemplo en el caso del Control Predictivo Generalizado (GPC) se utilizan modelos CARIMA (Controlled Auto-Regressive Integrated Moving Average) con polinomios de filtrado $T(z-1)$ para mejorar la robustez (Clarke, 1987).

4.5.1.2 Función de costo

La evolución dinámica de los procesos se pueden agrupar en dos grandes grupos (Ramos Fernández, 2007):

1. Parámetros descriptivos de la evolución temporal de la variable controlada, como es el error en régimen permanente, el valor final, el tiempo de establecimiento, la sobre-oscilación, la frecuencia de las oscilaciones, el tiempo de subida, etc.

2. Medidas de la desviación de la variable controlada respecto de la referencia, que se puede plasmar con una expresión general del tipo

$$\int_0^{\infty} f(r(t), y(t), t) dt \quad 4.54$$

Habitualmente se han utilizado integrales de una función del error, siendo las más extendidas en su uso (Marlin, 1995), el IAE (integral del valor absoluto del error), el ISE (integral del error al cuadrado), el ITAE (integral del producto del tiempo por el valor absoluto del error) y

el ITSE (integral del producto del tiempo por el error al cuadrado), entre otros, tal y como se muestra en la tabla 4.1.

Tabla 4. 1 Principales índices de funcionamiento.

Índice	Expresión
IAE	$\int_0^{\infty} r(t) - y(t) dt$
ISE	$\int_0^{\infty} (r(t) - y(t))^2 dt$
ITAE	$\int_0^{\infty} t r(t) - y(t) dt$
ITSE	$\int_0^{\infty} t(r(t) - y(t))^2 dt$

entre estas dos opciones, parece claro que es más apropiado utilizar parámetros del primer grupo, ya que las medidas de tipo integral no reflejan directamente cómo funciona el sistema. Sólo con el valor del índice un operado es incapaz de saber con cierto grado de exactitud cómo está funcionando el sistema. A esto se une que es más usual especificar el funcionamiento de un proceso en términos del tipo tiempo de establecimiento y sobreoscilación menores que unos valores determinados. Sin embargo, con los indicadores de tipo integral se puede incorporar en la evaluación del funcionamiento otro tipo de elementos como por ejemplo, el valor de la acción de control o ponderaciones de las distintas variables y, adicionalmente, se pueden usar para incluir en el índice la evaluación de costos económicos.

En general, no existe una formulación universal que sea válida para todos los problemas de control ya que cada tipo de indicadores tiene sus ventajas e inconvenientes. El índice de funcionamiento más adecuado para un problema concreto depende de los objetivos que se impongan y de las herramientas disponibles.

3. Una alternativa que trata de **combinar los dos tipos** de indicadores es la de establecer unas trayectorias de referencia en un índice de tipo integral. En lugar de utilizar una referencia de tipo escalón $r(t)$, se filtra mediante una función de transferencia $P(s)$ que fije la dinámica deseada de bucle cerrado: tiempo de establecimiento, sobreoscilación y régimen permanente, y se utiliza esta nueva respuesta $w(t)$ como referencia en un índice de funcionamiento de tipo integral

$$w(s)=P(s) r(s) \rightarrow w(t) \quad 4.55$$

$$I = \int_0^{\infty} f(w(t), y(t), u(t), t) dt \quad 4.56$$

Una función de coste de este tipo es la que se va a usar en control predictivo. Su traducción al entorno del control predictivo es directa, ya que operando con señales discretas el índice de coste debe, de alguna forma, imponer el funcionamiento deseado para el proceso introduciendo además nuevas características y parámetros para posibilitar su aplicación al control en línea ya que se debe conseguir que el volumen de los cálculos a realizar sea razonable.

Se puede generalizar, por tanto, como función de coste la expresión siguiente:

$$J(u) = \sum_{k=N_1}^{N_2} f(w(t+k), y(t+k|t), u(t+k|t), \alpha(k), \lambda(k), Nu, t) \quad 4.57$$

donde el significado de cada uno de los parámetros es:

Horizonte de predicción ($N=N_2-N_1+1$): intervalo de tiempo en el que se realiza la predicción, deber ser finito para que sea posible su aplicación al control en línea. Un horizonte de predicción infinito o demasiado grande hace que los cálculos de las predicciones no se puedan realizar en línea, salvo que exista una formulación analítica.

Horizonte de control (Nu): intervalo del horizonte de predicción en el que se permiten variaciones de la variable manipulada. Este parámetro se utiliza para simplificar el problema de optimización, ya que si reduce el número de variaciones se reduce el número de variables en el problema. Cuando se limita el horizonte de control cabe la posibilidad de realizar distintas estructuraciones de las acciones de control a lo largo del horizonte de control.

Factores de ponderación para los errores de predicción, $\alpha(k)$, y para las acciones de control, $\lambda(k)$. Estos factores se utilizan para conseguir distintos efectos en el comportamiento de bucle cerrado. Por ejemplo, mayor influencia del esfuerzo de control respecto a los errores de predicción o menor influencia en el índice de las predicciones más alejadas, o mayor ponderación de unas determinadas variables en detrimento de otras, etc.

Restricciones. Puede aparecer además, un conjunto de restricciones adicionales, en algunos casos duras o blandas, sobre variables de entrada, salida e internas. Estas restricciones pueden ser debidas tanto a limitaciones físicas del proceso como a especificaciones de funcionamiento.

4.5.1.3 Optimizador

Finalmente el control predictivo basado en modelos no es más (ni menos) que un problema de optimización. El objetivo del optimizador consiste en conseguir la combinación de acciones de control que optimice la función de coste. En la mayoría de los casos, la función de coste f es cuadrática debido principalmente a que la minimización de dicho índice sujeto a restricciones lineales es matemáticamente tratable (problema de programación cuadrática, QP). Existen otras aproximaciones manejando índices de coste modulares (Genceli, 1993), (Salcedo J. M., 2000), (Blasco, 1999) o con norma infinita (Rao, 1998) que no resultan tan sencillas de manejar y que, en presencia de restricciones lineales, terminan resolviendo problemas de programación lineal (LP). En general, el problema de optimización se puede llevar a cabo de dos formas:

a) Analíticamente. Sería la solución ideal e implicaría disponer de una expresión matemática que calcule el óptimo en función de las medidas hasta el instante t . Esto se puede conseguir cuando el modelo es lineal y la función de coste cuadrática y sin restricciones. En estos casos, el problema de optimización se resuelve fuera de línea y el análisis del sistema resultante se puede realizar utilizando las herramientas clásicas de la teoría de control.

b) Numéricamente. Fuera del contexto anterior, es decir, con problemas no lineales (bien sea por los modelos utilizados, bien por la aparición de restricciones, etc.), el control predictivo se convierte en un problema de optimización en cada periodo de muestreo con el consiguiente incremento de complejidad (resultando en un controlador no lineal y en un bucle cerrado también no lineal). En este caso, el método de optimización cobra más protagonismo cuando se pretende aplicar el control predictivo en línea, ya que las restricciones temporales son mayores, y por ello, por muy bueno que sea el modelo o muy acertada la función de coste, el

cuello de botella es la técnica de optimización. Una selección o ajuste inadecuado de esta técnica puede provocar en algunos casos, una pérdida notable de las prestaciones del control puesto que no se localiza correctamente el óptimo (Ramos Fernández, 2007).

4.5.2 Algoritmos de control predictivo

En seguida se presentan algunos de los algoritmos de control predictivo más utilizados.

1. Control con Matriz Dinámica, o Dynamic Matrix Control (DMC) (Cutler, 1980). Posteriormente se desarrolló el Quadratic DMC (QDMC) como extensión del DMC al caso con restricciones (García C. M., 1986). Las características de DMC haciendo referencia a los tres elementos del CPBM son (Ramos Fernández, 2007):

a) Predictor. El DMC usa un modelo del proceso basado en la respuesta ante escalón eligiendo sólo los primeros N términos, por lo que se asume que el proceso debe ser estable. En cuanto a las perturbaciones, considera que es el mismo que el del instante t para todo el horizonte de predicción, cuyo valor es igual al de la salida medida menos el valor de la salida predicha.

El principal inconveniente de este algoritmo es que la dimensión del modelo suele ser grande, y que no se puede usar con sistemas inestables.

b) La Función de costo puede considerar sólo los errores futuros o penalizar también el esfuerzo de control. Un aspecto que ha hecho este algoritmo muy popular en la industria es la fácil inclusión de restricciones.

c) La optimización es numérica al contemplar las restricciones, y se lleva a cabo en cada periodo de muestreo aplicando sólo la primera acción de control, siguiendo la filosofía horizonte móvil propia del CPBM.

2. Control Algorítmico basado en Modelos, o Model Algorithmic Control (MAC) (Richalet J. R., 1978), (Rouhani, 1982), (Richalet J. A., 1976). También llamado Control Predictivo Heurístico basado en Modelos o Model Predictive Heuristic Control (MPHC), el cual se

comercializa bajo el nombre Identification Command (IDCOM). Es parecido al DMC con las siguientes diferencias:

a) Predictor. El MAC utiliza un modelo basado en la respuesta impulsional, válido sólo para sistemas estables. Además no usa el concepto de horizonte de control N_u , por lo que el número de acciones de control calculadas equivalente al horizonte de predicción N . La consideración de la perturbación es como en el DMC, pero también se puede modelar como un sistema de primer orden.

b) La Función de costo es similar, pero se hace uso de una trayectoria de referencia en lugar de un set point, obtenida haciendo uso de un filtro de primer orden.

c) La optimización es similar al DMC, contemplando también la presencia de restricciones.

3. Control Predictivo Generalizado, o Generalized Predictive Control (GPC) (Clarke, 1987),

Las características del GPC son:

a) Las predicciones se basan en el modelo CARIMA (en función de transferencia), el cual modela la perturbación no medible, en parte, con un polinomio $T(z^{-1})$ que como es difícil de conocer se usa como parámetro de diseño. La obtención de la predicción óptima se lleva a cabo resolviendo una ecuación diofántica.

b) La Función de coste penaliza los errores y el esfuerzo de control, con los parámetros α y λ , respectivamente, a los cuales se les suele asignar un valor constante o exponencialmente creciente.

c) La optimización es similar al DMC. Para valores adecuados de los parámetros de diseño, el algoritmo es estable, e incluye, inherentemente en su estructura, controladores bien conocidos como son el mean level y el deadbeat.

4. Control Predictivo Funcional, o Predictive Functional Control (PFC) (Richalet J. S.-D., 1987). Este controlador fue propuesto por Richalet para procesos rápidos. Las características del PFC son:

a) Predictor. El PFC usa un modelo basado en espacio de estados y sirve tanto para sistemas lineales inestables como no lineales.

b) La Función de costo es similar al MAC pero sólo se considera un conjunto de puntos del horizonte de predicción, y no todo el horizonte completo, por lo que el problema de optimización resulta más sencillo (concepto llamado puntos coincidentes).

c) Otro concepto distintivo es que el controlador parametriza la acción de control haciendo uso de funciones base polinomiales, lo que permite considerar perfiles de la entrada relativamente complejos, pudiendo seguir referencias polinomiales sin retraso.

CAPÍTULO V
DESARROLLO Y
RESULTADOS OBTENIDOS

Modelado del motor de combustión interna diésel sobrealimentado. Las actividades consideradas para la obtención del sistema se realizaron tomando como base un modelado en Simulink de MATLAB de un motor de combustión interna a diésel del tipo sobrealimentado, este modelo fue facilitado por científicos de la Universidad Politécnica de Valencia. Dicho modelo se realizó considerando las ecuaciones del funcionamiento de cada elemento del motor de combustión interna a diésel sobrealimentado, este modelo se describió con detenimiento en la sección 2.4 del capítulo 2 de este documento. Esta opción fue la más viable y conveniente debido a que en la zona no se ubicó algún banco con motor de combustión interna, disponible para realizar pruebas. A dicho modelo se aplicaron métodos de identificación paramétrica con el fin de obtener un modelo compacto que representara de manera eficiente a un motor real de combustión interna del tipo sobrealimentado.

5.1 Identificación paramétrica del sistema

El método utilizado para la identificación es el más conocido: 1. Obtención de datos de entrada, 2. Tratamiento previo de los datos registrados, 3. Elección de la estructura del modelo, 4. Obtención de los parámetros del modelo, 5. Validación del modelo (Ljung, 1987), esta metodología se describe ampliamente en la sección 3.2.1 del capítulo 3. Ver figura 3.2.

5.1.1 Elección de las señales a medir

Debido a que el modelo disponible está en Simulink, se determina realizar el registro y consulta de las variables en este mismo programa, pues además es muy accesible para llevar a cabo estas tareas.

El punto de funcionamiento viene dado por las dos variables siguientes:

1. Cantidad de combustible inyectada (m_f), que viene dado por el movimiento del pedal del acelerador.
2. Régimen de giro del motor (N), que viene determinado por el par motor (N_e) y el par por la resistencia de la carretera.

Con el punto de funcionamiento definido el fabricante posee un mapa en el que se le indican las cantidades de gasto de aire (m_a) y de gasto de EGR (m_{EGR}) que se requieren para disminuir los humos y los óxidos de nitrógeno, así como para garantizar un determinado par motor. Este mapa también contiene información acerca de %TGV y de P_a .

Se considera como base para el análisis presentado en este trabajo, el sistema comercial de Bosch, las variables m_a y P_a se seleccionaron, partiendo del hecho de que los motores diésel sobrealimentados comerciales cuentan con estos dos sensores. Por otro lado, también se tienen dos actuadores para la regulación del grado de apertura de la turbina de geometría variable (TGV) y la abertura de la válvula de EGR (Recirculación de los gases de escape), buscando cumplir con las prestaciones requeridas por el usuario y tener niveles de óxido de nitrógeno por debajo de la normativa, por esta razón se consideran como elementos finales de control las válvulas EGR y TGV.

5.1.2 Elección de las entradas/salidas

En esta etapa se recabó la información de las entradas y salidas del sistema, se utilizó el sistema presentado y descrito en el capítulo II (ver la fig. 2.5). El sistema diseñado en Simulink de Matlab para la obtención de los datos es mostrado en la figura 5.1.

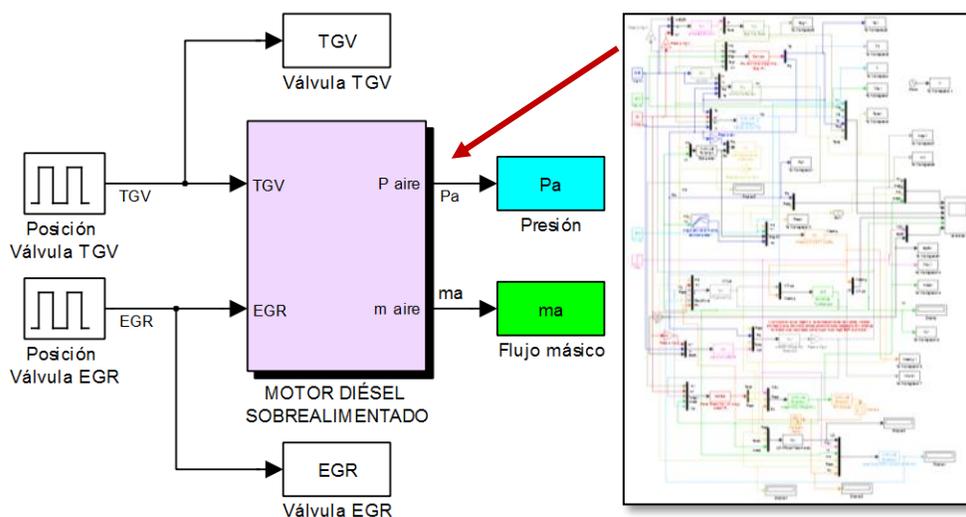


Figura 5. 1 Sistema con dos entradas y dos salidas del Motor Diésel Sobrealimentado

El sistema se excitó con señales de entrada de Secuencias Binarias Seudo-Aleatorias (SBSA). Se suministró una señal a cada entrada: apertura de la Válvula EGR (Recirculación de los gases de Escape) y apertura de la Válvula TGV (Turbina de Geometría Variable), así como se puede ver en la figura 5.1.

5.1.3 Pretratamiento de los datos

Se planteó el experimento para recopilar 50,000 datos. En los datos obtenidos para este proyecto no se presentaron perturbaciones de alta frecuencia, dichas perturbaciones son generadas por fuentes de ruido externas, debido a que el experimento y pruebas se desarrollaron a nivel de software no existieron elementos de ruido ajenos al sistema.

Se eliminaron los primeros 5,000 datos por considerarse no confiables, debido a que los diversos bloques del programa necesitaban tiempo para trabajar con plenitud.

5.1.4 Elección de la estructura del modelo

Se evaluaron varias estructuras, aquí solo se presentan las estructuras que nos dieron mejores resultados. Estas estructuras se describen en la sección

Estructura ARMAX:

$$A(q^{-1})y(t) = B(q^{-1}) \cdot u(t) + C(q^{-1}) \cdot e(t)$$

Estructura OE:

$$y(t) = \frac{B(q^{-1})}{F(q^{-1})} \cdot u(t) + e(t)$$

5.1.4.1 Simulación de estructura ARMAX

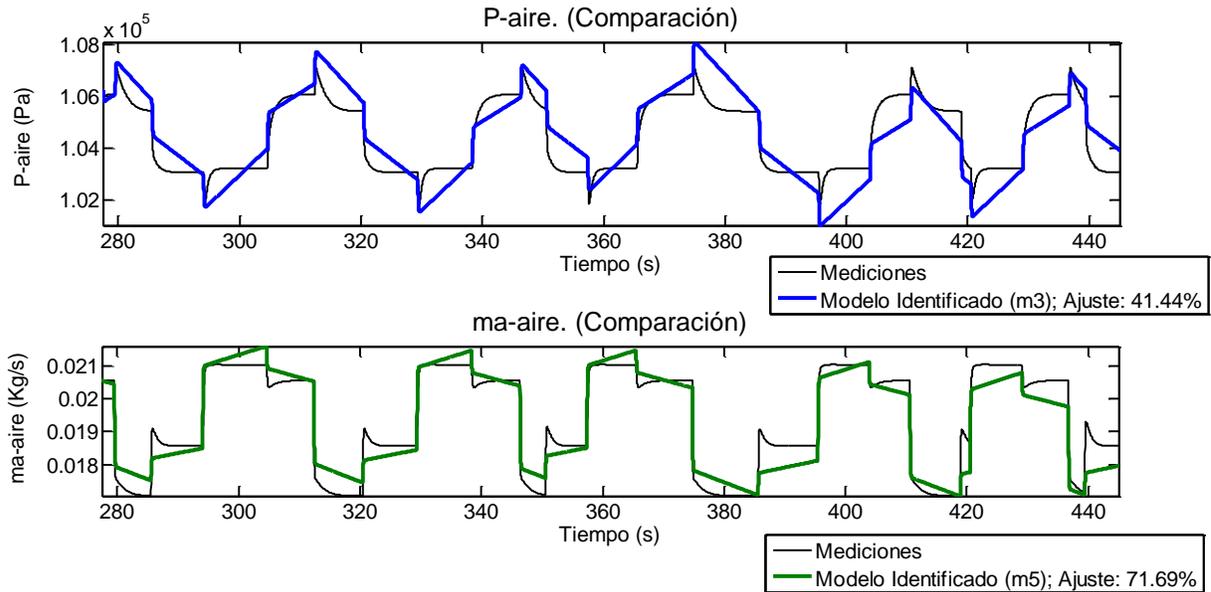


Figura 5. 2 Comparación entre el modelo obtenido con Armax y los datos medidos

5.1.4.2 Simulación de estructura OE

La segunda estimación se realizó con la estructura OE (error en la salida). La validación se realizó comparando la salida del modelo obtenido con los datos medidos, el resultado se presenta en la figura 5.3. Las aproximaciones conseguidas fueron del 89.4% y 82.17% para P-aire y ma-aire, respectivamente.

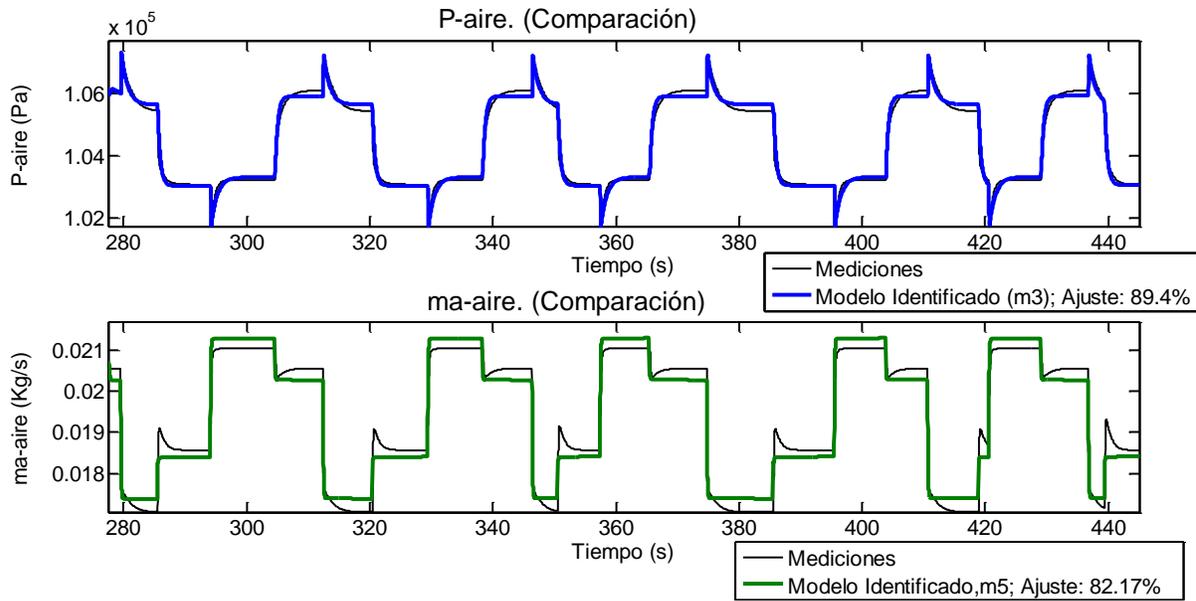


Figura 5. 3 Comparación entre el modelo obtenido con OE y los datos medidos

El modelo discreto obtenido se presenta en la figura 5.12. Se obtuvo corriendo en MatLab, el programa presentado en el anexo 2.1.

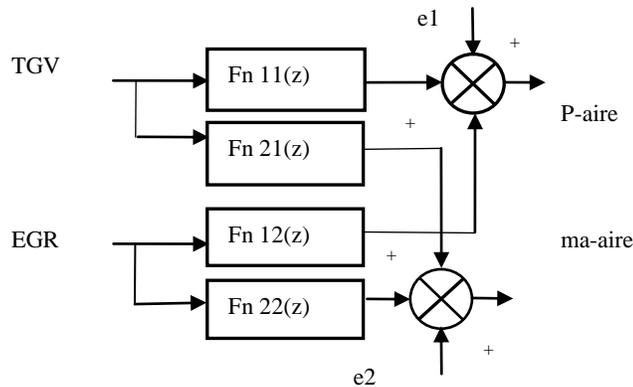


Figura 5. 4 Modelo Digital Multivariable, dos entradas y dos salidas

$$Fn11(z) = \frac{-19.69q^{-1} + 19.69q^{-2}}{1 - 1.977q^{-1} + 0.977q^{-2}} \quad (5.1)$$

$$Fn12(z) = \frac{106.3q^{-1} - 106.6q^{-2}}{1 - 1.747q^{-1} + 0.7492q^{-2}} \quad (5.2)$$

$$Fn21(z) = \frac{3.884e^{-5}q^{-1} - 3.884e^{-5}q^{-2}}{1 - 1.869q^{-1} + 0.869q^{-2}} \quad (5.3)$$

$$Fn22(z) = \frac{-0.0001453q^{-1} + 0.0001453q^{-2}}{1 - 1.852q^{-1} + 0.8523q^{-2}} \quad (5.4)$$

5.1.5 Validación del modelo

El proceso de validación de este modelo se dio de la siguiente manera:

5.2.5.1 Simulación

Los datos adquiridos para la prueba se dividieron en dos partes: la primera se utilizó para encontrar el modelo identificado y la segunda parte se ocupó para correr una simulación y validar el modelo, pues estos datos no tuvieron nada que ver con la obtención del modelo. Se aplicaron las mismas entradas al sistema y se corrió la simulación, los resultados obtenidos se presentan en la figura 5.11.

5.1.5.2 Análisis de residuos

Se conoce así, a los errores de predicción calculados con la siguiente expresión:

$$\mathcal{E}(t) = \mathcal{E}(t, \theta) = y(t) - y_e(t, \theta) \quad \text{ecuación 3.58}$$

siendo θ el vector de parámetros del modelo, $y(t)$ la respuesta real del sistema e $y_e(t)$ la respuesta estimada por el modelo para la misma entrada.

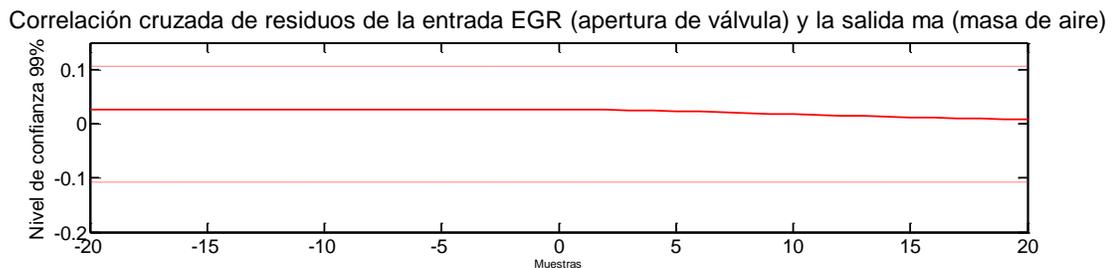


Figura 5. 5 Análisis de residuos del modelo EGR-ma

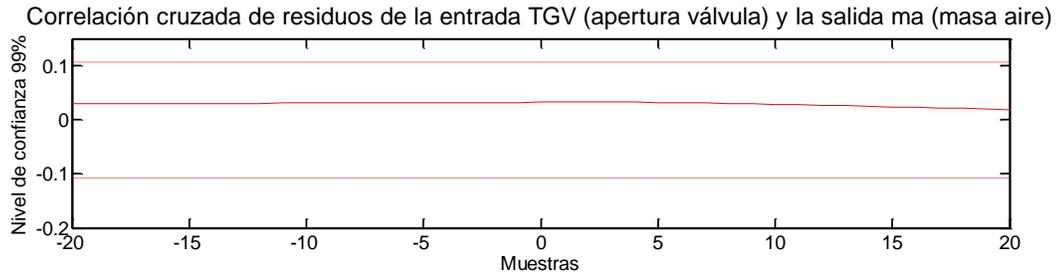


Figura 5. 6 Análisis de residuos del modelo TGV-ma

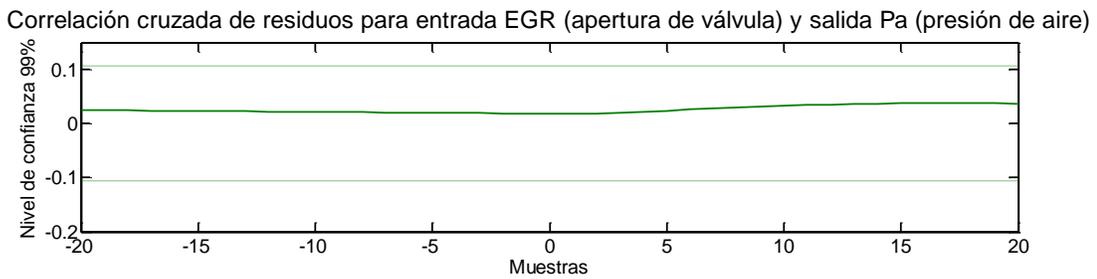


Figura 5. 7 Análisis de residuos del modelo EGR-Pa

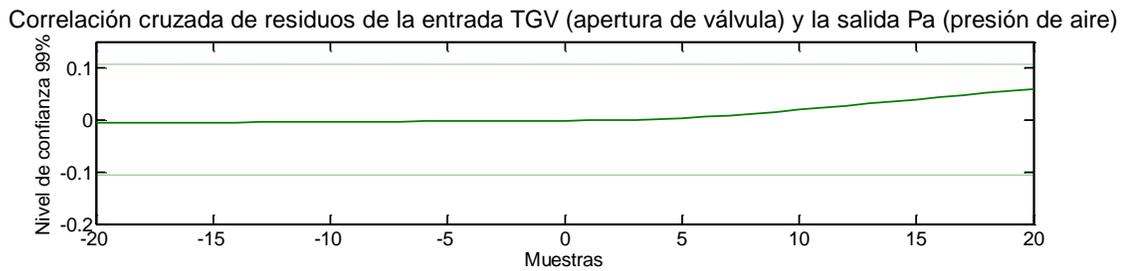


Figura 5. 8 Análisis de residuos del modelo TGV-Pa

Debido a que la correlación no se sale del margen de validez, se concluye que la dinámica del sistema queda suficientemente caracterizada con el modelo escogido.

5.2 Modelo de identificación con Red Neuronal Artificial (RNA)

5.2.1. Selección de las variables de entrada/salida

La elección de las variables atiende al hecho de utilizar parámetros directos del motor que no necesiten de modelos intermedios ni procesos preliminares para ser utilizados como datos de entrada a la RNA.

La predicción de las emisiones de escape es esencial para poder disminuirlas y así evitar alteraciones tanto al medio ambiente como a la salud de la población.

Aparte de las consideraciones técnicas se tomó en cuenta la disponibilidad de la información, pues como se había comentado, solo se cuenta con un modelo desarrollado en Simulink con características específicas y monitoreo de variables bien definidas.

Tabla 5. 1 Variables respuesta del motor de combustión interna Diésel a predecir con RNA

SALIDAS	NOMENCLATURA
*Óxidos de nitrógeno	NO _x
Partículas	PM
*Monóxido de carbono	CO
*Hidrocarburos sin quemar	HC
Consumo específico	BSFC
*Temperatura de escape	Tex

Tabla 5. 2 Variables del motor de combustión interna Diésel que tienen influencia tanto en las emisiones como en el consumo y en la temperatura de escape (Hernández López, 2006)

ENTRADAS PRINCIPALES	UNIDADES	ABREVIATURA
*Régimen de giro del motor	rpm	n
*Masa de combustible	Kg/h	Mf
*Masa aire	Kg/h	Ma
*Gases de escape recirculados	%	EGR
*Presión de inyección	bar	IP
*Avance de inyección principal	°CAD	SOIpr
*Avance de inyección piloto	°CAD	SOIpi
*Temperatura del aire en la admisión	°C	Tadm
Temperatura del agua de refrigeración	°C	Tw
Diámetro de tobera	mm	Dt

Las marcadas con asterisco (*) son entradas y salidas consideradas para el modelo propuesto.

5.2.2 Preprocesamiento de datos

Se suelen normalizar los datos de manera que estén dentro de un intervalo específico (por ejemplo (0,1) ó (-1, 1)). Se calculó la norma de los datos siguiendo la siguiente fórmula:

$$\text{Norma de X} = \|X\| = (X^T X)^{1/2} = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$$

5.2.3. Elección de la arquitectura de la red

Leonor Hernández comentó lo siguiente:

Las neuronas de la capa final de una salida suelen utilizar funciones de activación identidad (función lineal), mientras que para los demás elementos de procesado se suelen utilizar funciones no lineales. Estas no linealidades pueden ser modeladas con funciones de tipo

escalón, cuya respuesta es más fiel a la respuesta biológica, o con sigmoides, cuyo comportamiento matemático es menos hostil.

Las funciones de activación se eligieron de tipo **sigmoide** binaria para las neuronas de la capa oculta y **lineales** para la capa de salida.

La arquitectura de la red es la siguiente:

La capa de **neuronas de entrada** cuenta con ocho neuronas, el número coincide con el número de entradas que fueron seleccionadas:

1. Régimen de giro del motor
2. Masa de combustible
3. Masa aire
4. Gases de escape recirculados
5. Presión de inyección
6. Avance de inyección principal
7. Avance de inyección piloto
8. Temperatura del aire en la admisión

Cada neurona tiene una entrada que proviene del exterior y varias salidas conectadas a las capas posteriores.

La arquitectura cuenta con una capa oculta de ocho neuronas, al tener solo una capa oculta se minimiza el riesgo de estancar los entrenamientos en mínimos locales, más comunes en estructuras de dos o más capas (Hernández López, 2006). Las neuronas de la capa oculta son las que realizan el trabajo y no tienen contacto las señales externas de la red. Cuenta además con cuatro neuronas en la capa de salida, es la capa que transmite la información generada por la red al exterior, el número de neuronas de esta capa coincide con el número de salidas de la RNA.

Las salidas son:

1. Óxidos de nitrógeno
2. Monóxido de carbono
3. Hidrocarburos sin quemar
4. Temperatura gases de escape

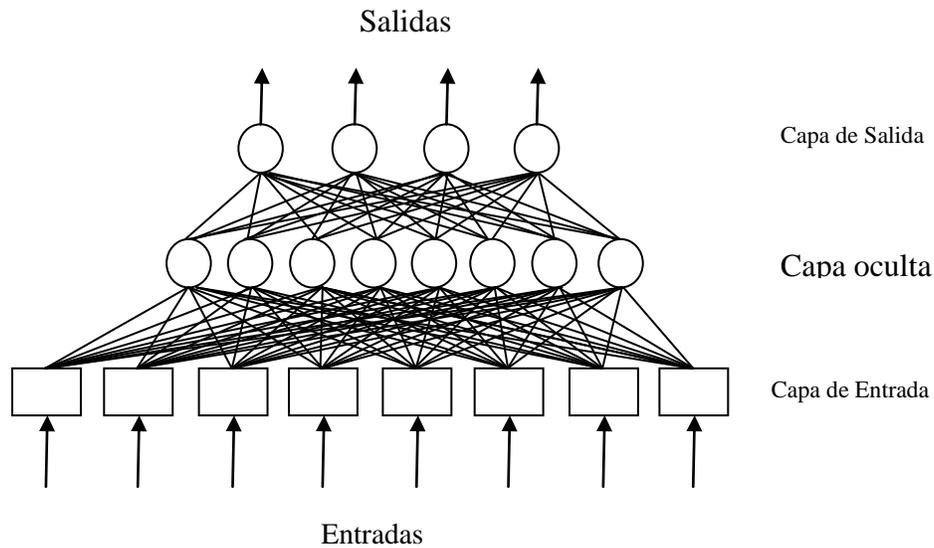


Figura 5. 9 Red Neuronal Perceptrón: 8 entradas, 1 capa oculta de 8 neuronas y 4 salidas

5.2.4. Procedimiento de iniciación y descripción del algoritmo de entrenamiento

El algoritmo de entrenamiento requiere de un valor inicial de los pesos, que será el punto de partida de la optimización del error de las RNA. Para este caso la ponderación inicial de los pesos se determina sea de manera aleatoria.

El algoritmo de Backpropagation usado es el de Levenberg-Marquardt, éste es el método de entrenamiento rápido y que suele ser el recomendado para arquitecturas pequeñas o medianas.

El valor irá cambiando a lo largo de las iteraciones a partir de un valor inicial (μ_{in}), mediante unas razones incremento (μ_{inc}) y de decrecimiento (μ_{dec}).

La actualización de los pesos en el entrenamiento se realizó mediante la estrategia por lotes "batch", donde la RNA cambia los pesos tras ver todos los patrones de entrenamiento. Se considera una época cuando todos los patrones de entrenamiento han sido presentados a la red.

Los criterios de parada del entrenamiento para la primera fase se fijaron en un máximo de 200 épocas y un mínimo de 1^{-8} en el error MSE.

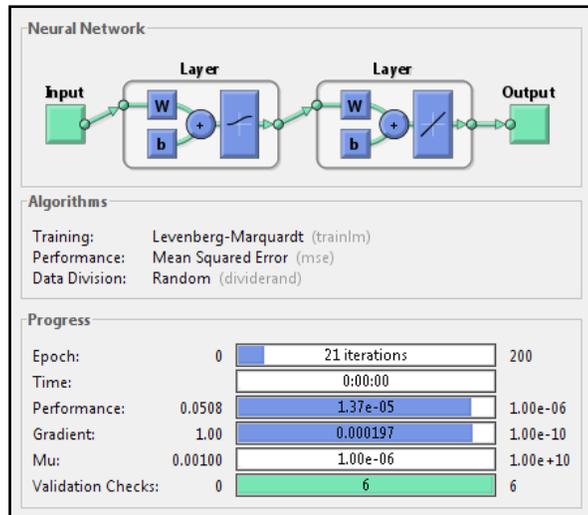


Figura 5. 10 Resultados del Programa en MatLab

El algoritmo de Backpropagation usado es el de Levenberg-Marquardt, ya que es el tipo de entrenamiento bastante rápido y que suele ser recomendado para arquitecturas pequeñas o medianas (Hernández López, 2006).

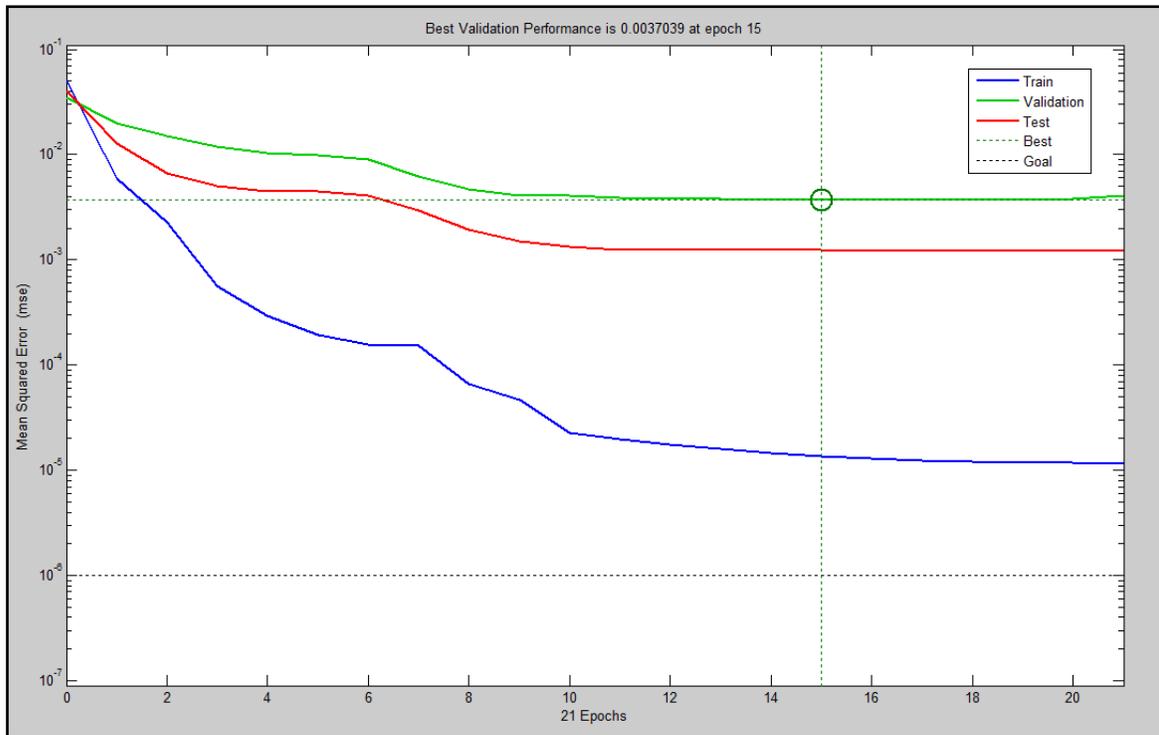


Figura 5. 11 Resultados gráficos del entrenamiento (train), validación (validation) y prueba (test).

Se puede ver que ambos errores disminuyen, se observa que no hay sobre-entrenamiento debido a que el paro del proceso se dio cuando el error de validación era mínimo y el error de validación también iba disminuyendo.

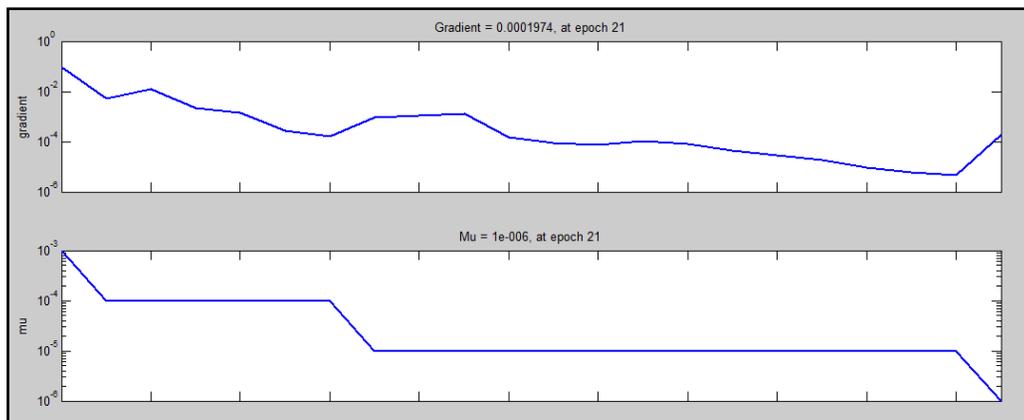


Figura 5. 12 Gráfica de Resultados

En las gráficas siguientes se pueden ver rectas de regresión lineal del conjunto de datos considerados (trazo continuo) y la que correspondería a una correlación perfecta $Y=T$ (trazo discontinuo).

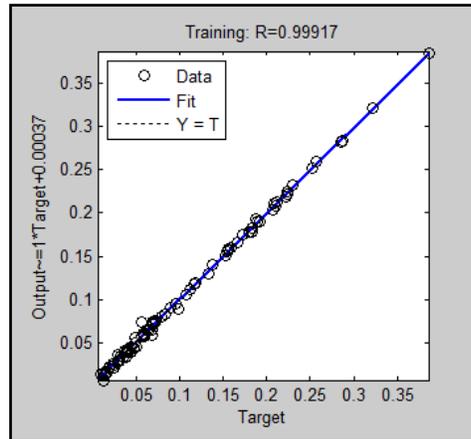


Figura 5. 13 Regresión lineal del entrenamiento

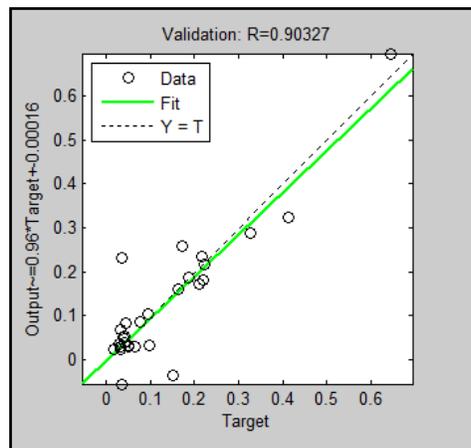


Figura 5. 14 Regresión lineal de la validación

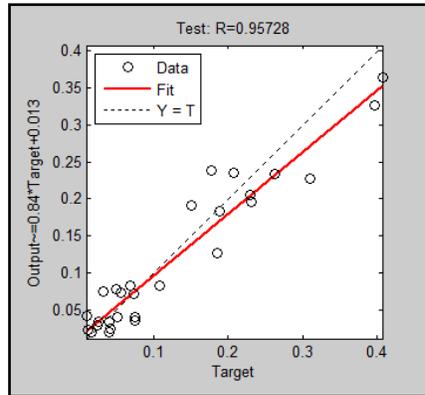


Figura 5. 15 Regresión lineal de la prueba

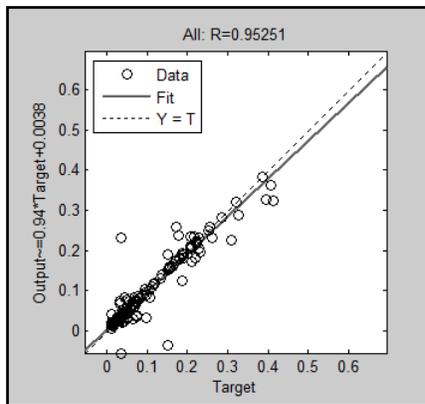


Figura 5. 16 Regresión lineal promedio

Se utilizó el comando "sim" de Matlab para correr los valores de prueba en el modelo de RNA con los parámetros propuestos y los pesos calculados.

Tabla 5. 3 Datos de simulación de la RNA

Simulación RNA:	Dato real:	Simulación RNA:	Dato real:	Simulación RNA:	Dato real:
>>sim(net,pp1) ans = 0.0088 0.0462 0.4717 0.1567	>> sp1 sp1 = 0.0155 0.0368 0.3637 0.1434	sim(net,pp2) ans = 0.0305 0.0280 0.1796 0.1863	>> sp2 sp2 = 0.0318 0.0226 0.1643 0.1951	sim(net,pp3) ans = 0.1230 0.0401 0.0965 0.1055	>> sp3 sp3 = 0.1286 0.0115 0.0684 0.0956
sim(net,pp4) ans = 0.1634 0.0423 0.0273 0.0452	>> sp4 sp4 = 0.1410 0.0148 0.0584 0.0396	sim(net,pp5) ans = 0.1727 0.0075 0.0651 0.0416	>> sp5 sp5 = 0.1802 0.0173 0.0871 0.0420	sim(net,pp6) ans = 0.0252 0.0086 0.1140 0.3032	>> sp6 sp6 = 0.0233 0.0531 0.1721 0.2590
sim(net,pp7) ans = 0.1944 0.0050 0.0957 0.0386	>> sp7 sp7 = 0.2008 0.0200 0.0767 0.0490	sim(net,pp8) ans = 0.1472 0.0144 0.0514 0.0282	>> sp8 sp8 = 0.1394 0.0164 0.0574 0.0400	sim(net,pp9) ans = 0.2014 0.2544 0.0952 0.0661	>> sp9 sp9 = 0.2055 0.0432 0.0664 0.0452

5.3 Diseño y simulación del controlador PID

5.3.1 Desacoplamiento parcial del sistema

Aplicando el método de conexiones Feed Forward y desacoplamiento de sistemas multivariables, sección 4.3.6.1; al sistema multivariable calculado en el apartado 5.1.4.2, estructura OE.

Utilizando la metodología presentada, desacoplamiento parcial, en la figura 4.4, se calculan las funciones de desacoplamiento:

$$FF1(z) = 3.305 \frac{z-0.862}{(z-0.859)} \quad (5.9)$$

$$FF2(z) = 5.400 \frac{z-0.977}{(z-0.749)} \quad (5.10)$$

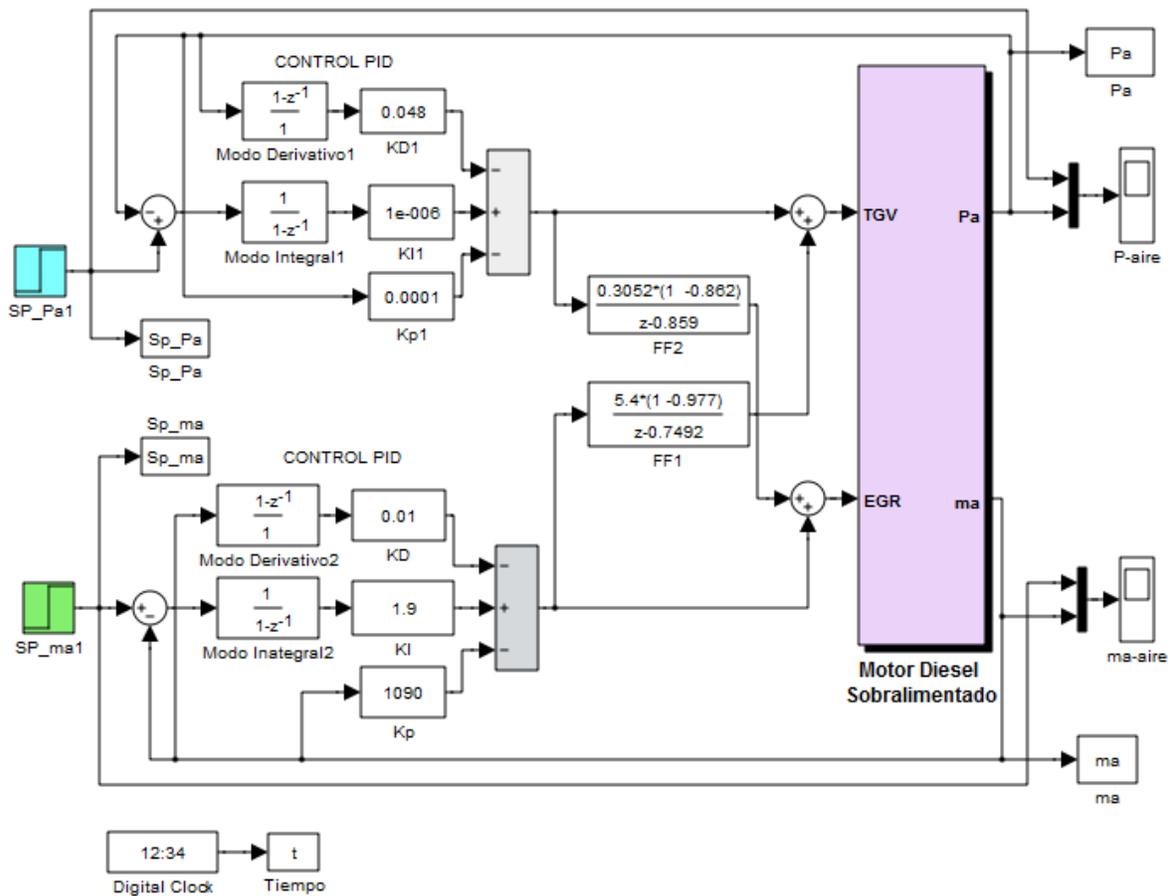


Figura 5. 17 Sistema desacoplado, contralado por un PID

Se obtuvieron los siguientes resultados:

El setpoint (línea azul) y la variable Presión del Aire, Pa (línea color negro), ver figura 5.19.

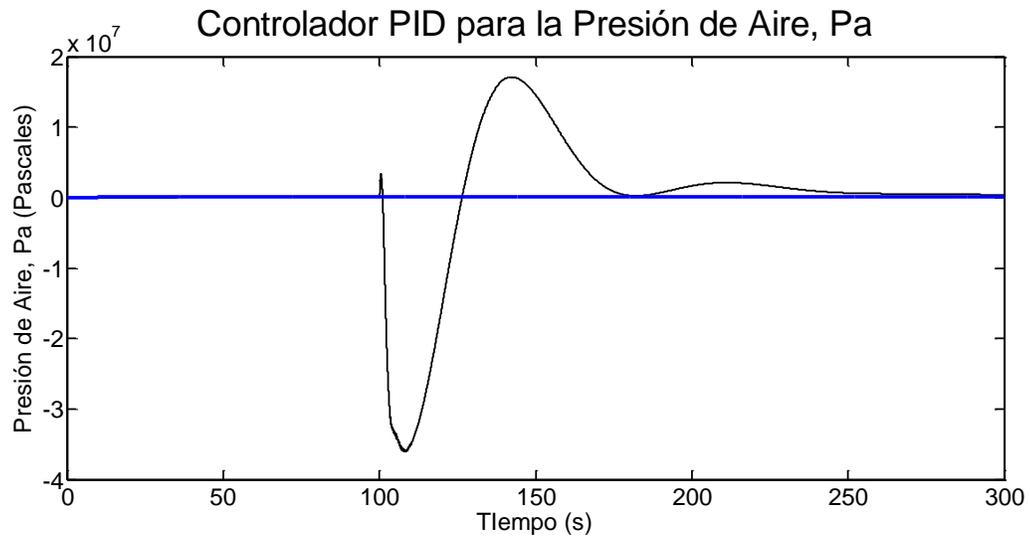


Figura 5. 18 Presión del aire, Pa, controlada por un PID

El valor deseado (línea verde) y la variable masa del Aire, ma (línea color negro), ver figura 5.20.

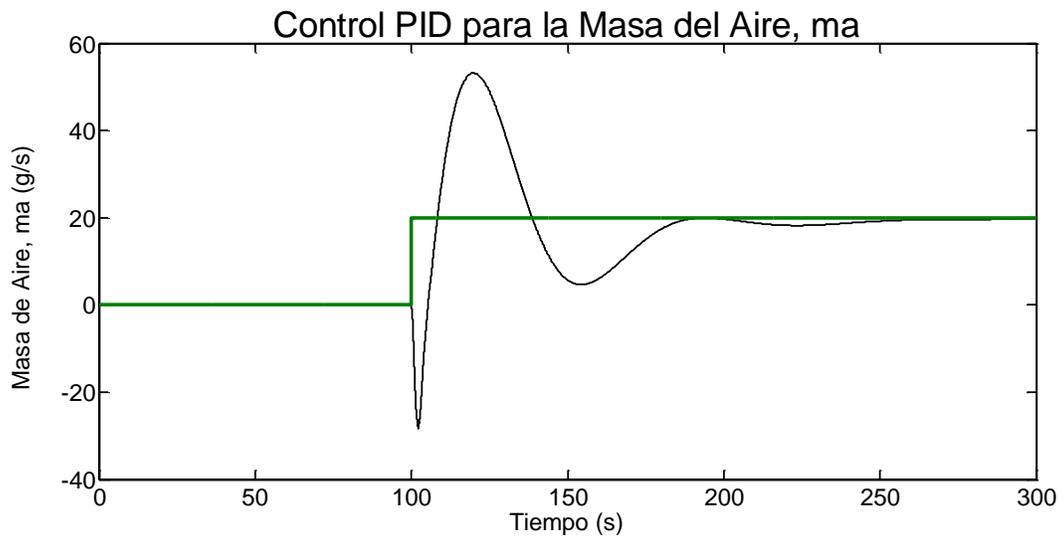


Figura 5. 19 Masa del aire, ma, controlada por un PID

5.4 Diseño y simulación del sistema desacoplado completamente + controlador.

5.4.1 Desacople del sistema.

Utilizando el planteamiento propuesto de desacoplamiento completo, en la figura 4.5, se calcula el proceso + desacoplador del sistema:

$$G1(z) = 8.725 \frac{z-1.49}{(z-1)(z-0.73)} \quad (5.11)$$

$$G2(z) = 6.5e^{-5} \frac{z-0.8138}{(z-1)(z-0.74)} \quad (5.12)$$

5.4.2 Diseño y simulación de controladores en tiempo discreto $G_D(z)$.

Aplicando la metodología descrita en la sección 4.4 de esta tesis, se obtuvieron los siguientes controladores:

$$G_{D1}(z) = \frac{-0.2339(z-0.73)}{z-3.04} \quad (5.13)$$

$$G_{D2}(z) = \frac{8.22 e^4 (z-0.74)}{z-4.3476} \quad (5.49)$$

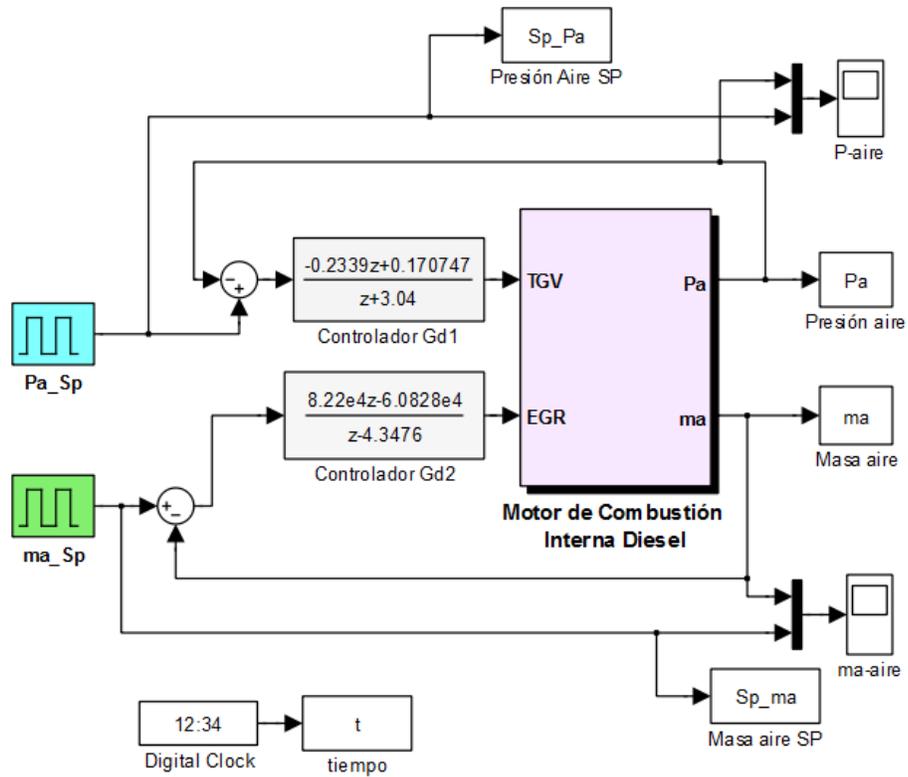


Figura 5. 20 Sistema con controladores en tiempo discreto

El setpoint (línea azul) y la variable Presión del Aire, Pa (línea color negro), ver figura 5.22.

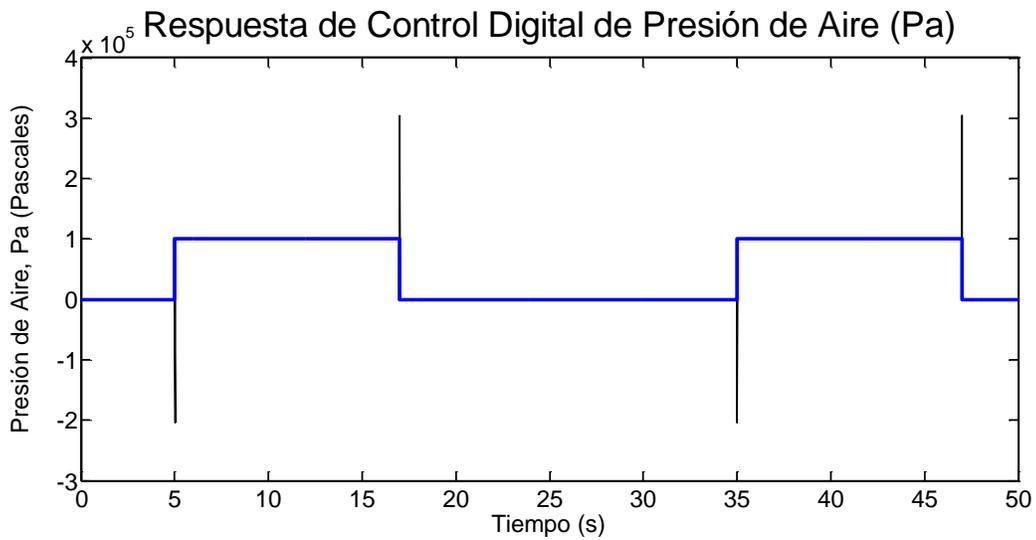


Figura 5. 21 Presión del aire, Pa, controlada por controlador en tiempo discreto

El valor deseado (línea verde) y la variable masa del Aire, ma (línea color negro), ver figura 5.23.

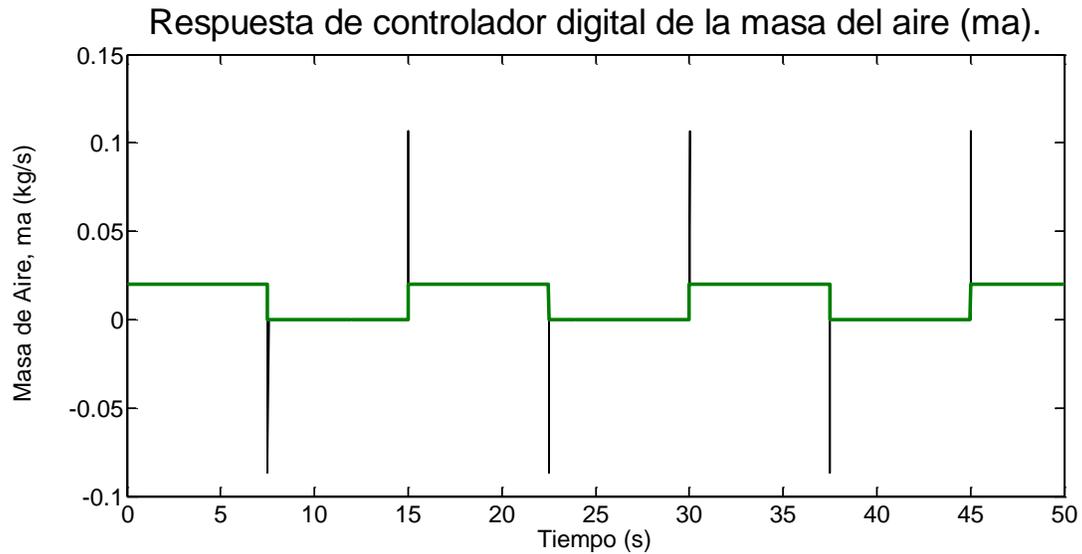


Figura 5. 22 Masa del aire, ma , controlada por controlador en tiempo discreto

5.5 Diseño y simulación de un Controlador Predictivo Basados en Modelos (CPBM).

Este tipo de controlador se describió en la sección 4.5, en la figura 5.23 se puede ver el sistema completo. Para mejorar los resultados con esta metodología, se adecuaron las unidades de la variable ma , masa del aire, pues originalmente estaban en Kg/s y se realizó la modificación en el modelo original para tener los resultados de la identificación en g/s, esto evitó el manejo de valores medidos muy pequeños.

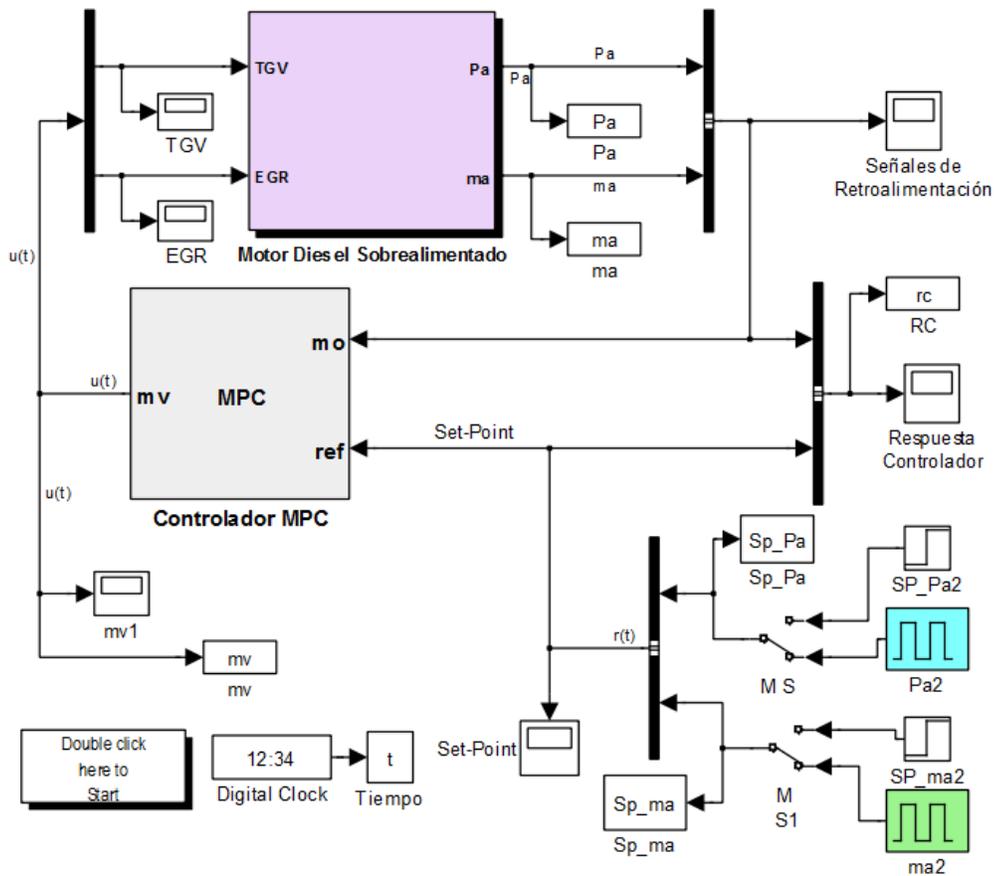


Figura 5. 23 CPBM para controlar Pa y ma de un motor de combustión interna diésel

El setpoint (línea azul) y la variable Presión del Aire, Pa (línea color negro), ver figura 5.24.

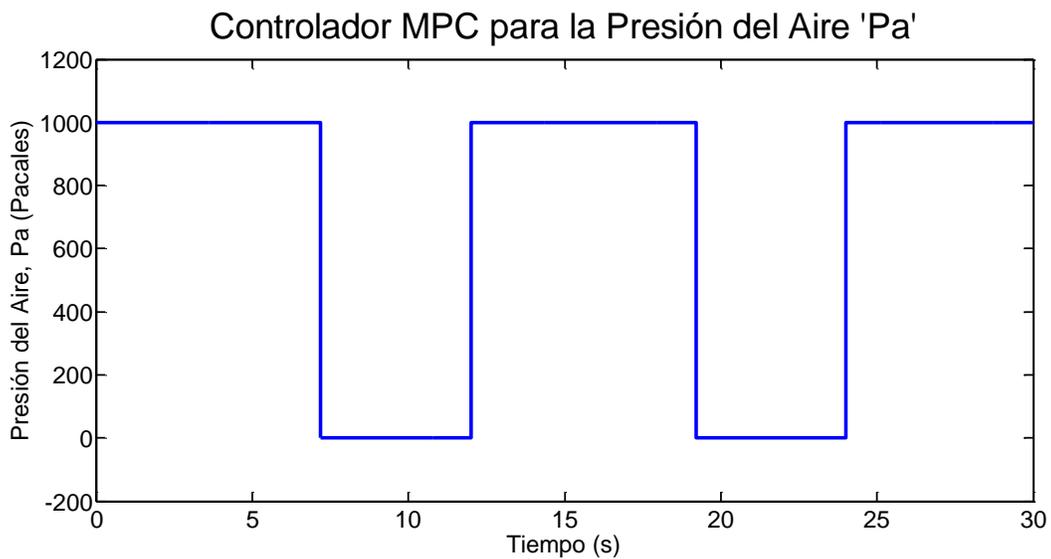


Figura 5. 24 Presión del aire, Pa, controlada por un CPBM

El valor deseado (línea verde) y la variable masa del Aire, ma (línea color negro), ver fig. 5.25.

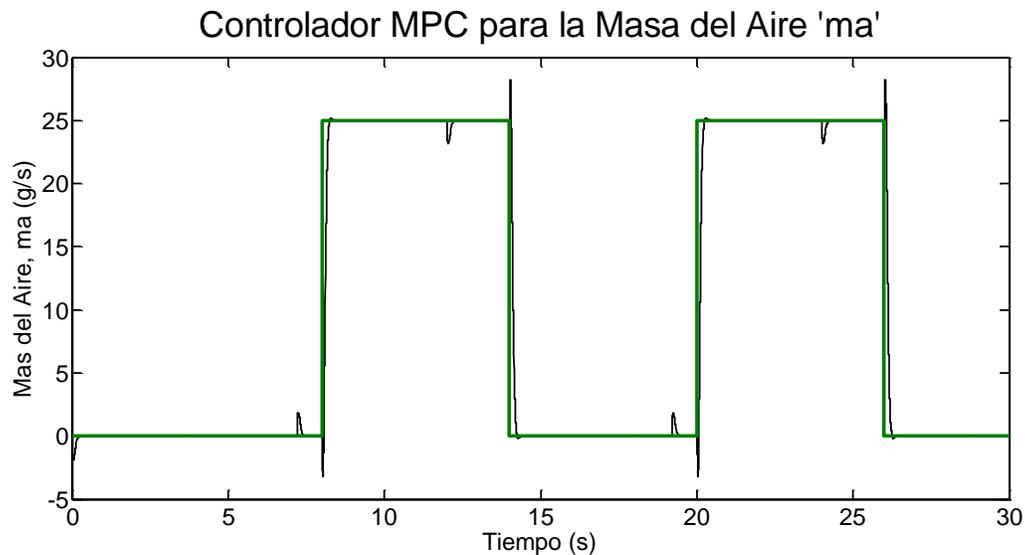


Figura 5. 25 Masa del aire, ma , controlada por un CPBM

5.6 Validación de resultados

Se llevó a cabo una comparación de resultados entre los obtenidos en este trabajo y los que presentan unos investigadores de la Universidad Politécnica de Valencia (Salcedo, Blasco, Martínez, & García, 2001) donde se desarrolló un modelo simplificado de compresor-motor-circuito EGR + turbina, tal como el presentado en la figura 2.5. Este modelo se describió en la sección 2.4. En él se utilizaron ecuaciones diferenciales y ecuaciones estáticas, así como tablas de datos obtenidas de experimentos llevados a cabo con un motor diésel real. En dicho artículo se plantea, además, una propuesta de control para las variables P_a (presión del aire) y ma (masa del aire). Obtuvieron un modelo multivariable, a partir del modelo mencionado, (ver ecuación 1.1 de la sección 1.6), de 2×2 , y con base en éste se diseñaron dos controladores PI, mediante el método de cancelación de polos de lazo abierto, uno para controlar P_a y otro para ma , obteniendo los siguientes resultados (ver figuras 5.26 y 5.27). Para la simulación se aplicó

un escalón de 0.005 Kg/s en la referencia de ma y un escalón de amplitud 500 en la referencia de Pa.

Ver figura 5.26. La línea en color negro es el valor deseado y la línea azul es la variable de proceso, Pa.

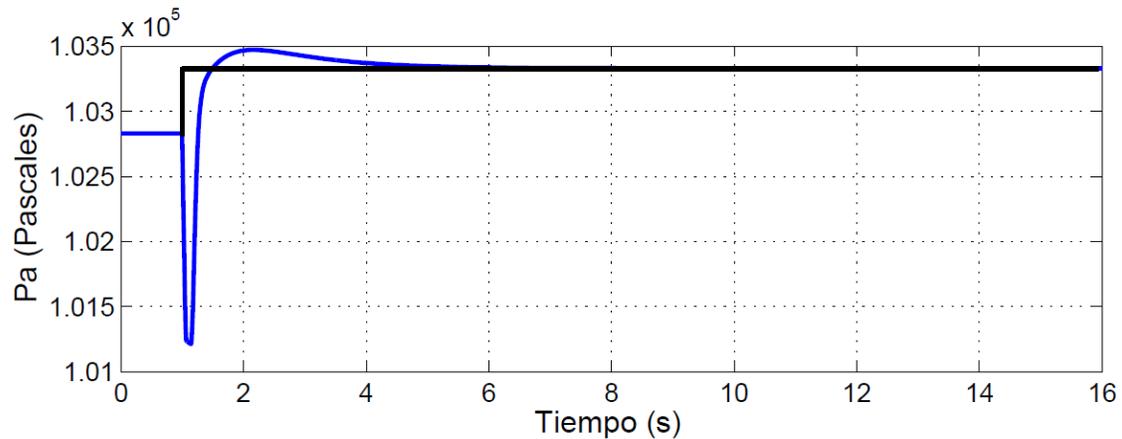


Figura 5. 26 Simulación del controlador PI para el control de la presión del aire, Pa.
(Salcedo, Blasco, Martínez, & García, 2001)

Ver figura 5.27. La línea en color negro es el valor deseado y la línea verde es la variable de proceso, ma.

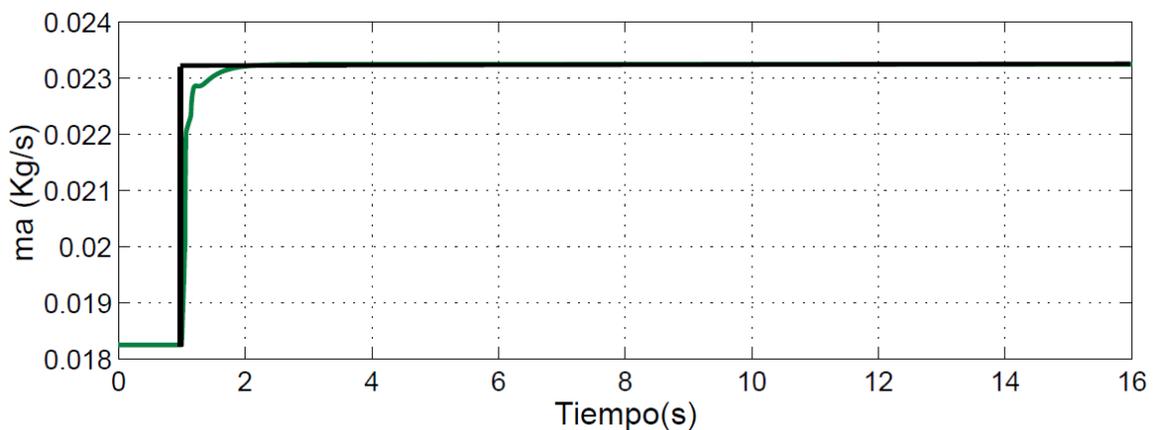


Figura 5. 27 Simulación del controlador PI para el control de la masa del aire, ma.
(Salcedo, Blasco, Martínez, & García, 2001)

Para realizar una comparación con los resultados de este trabajo se establecieron condiciones de simulación similares, considerando que ambos modelos se ejecutaron en Simulink de Matlab: Tiempo de simulación de 16 seg y un paso (Fixed -step) de 0.01. Es decir, evaluará 100 datos por cada segundo mostrado en la gráfica. Cabe señalar que el tiempo mostrado no corresponde al tiempo real, pues depende de la complejidad de los cálculos que tenga que realizar el software.

La línea en azul es el valor deseado y la línea color negro es la variable de proceso, Pa, figura 5.28.

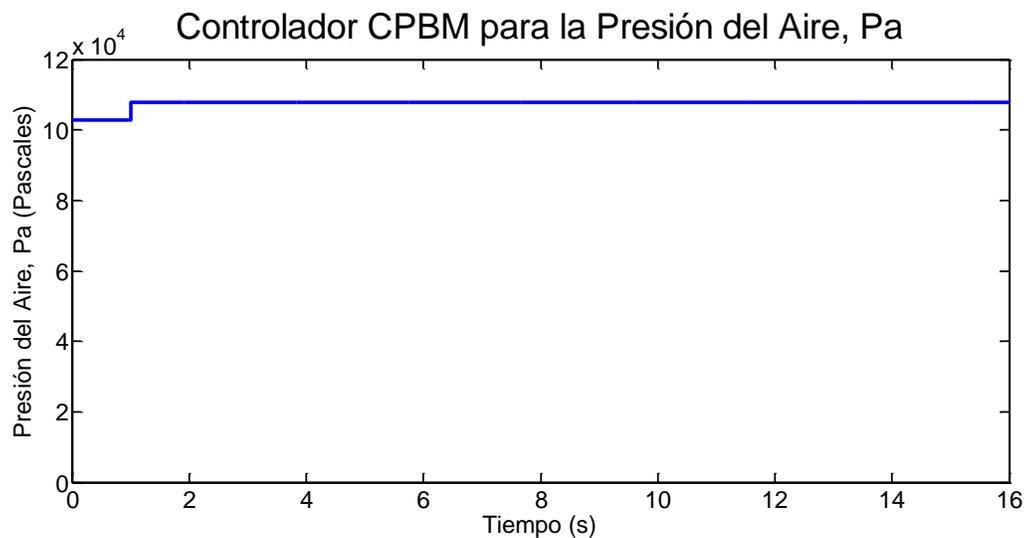


Figura 5. 28 Simulación del MPC para el control de la presión del aire, Pa.

La línea en verde es el valor deseado y la línea en negro es la variable de proceso, ma. Se observa al inicio un valle pronunciado, debido a que las condiciones iniciales son diferentes de cero.

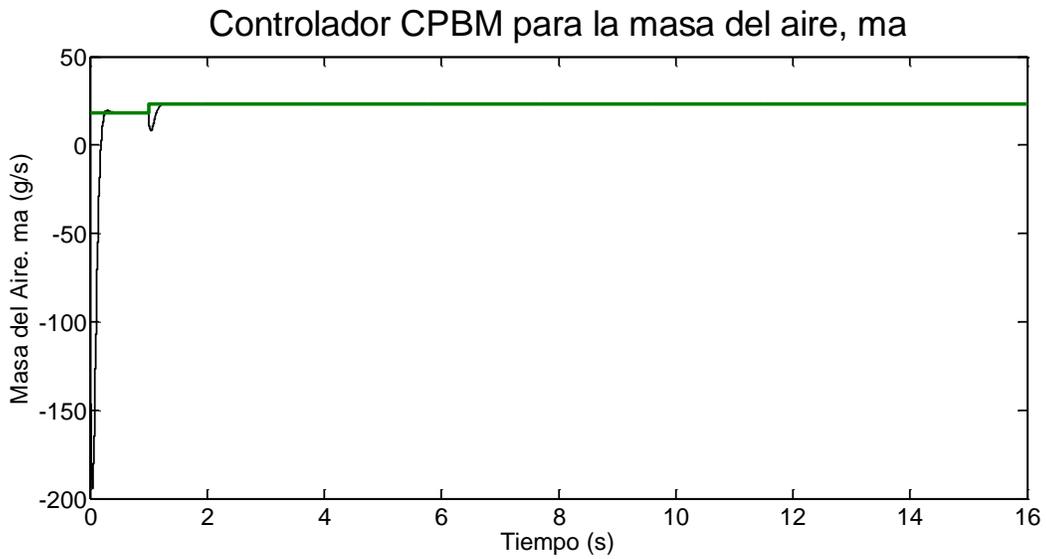


Figura 5. 29 Simulación del MPC para el control de la masa del aire, ma.

La línea en azul es el valor deseado y la línea color negro es la variable de proceso, Pa, fig. 5.30.

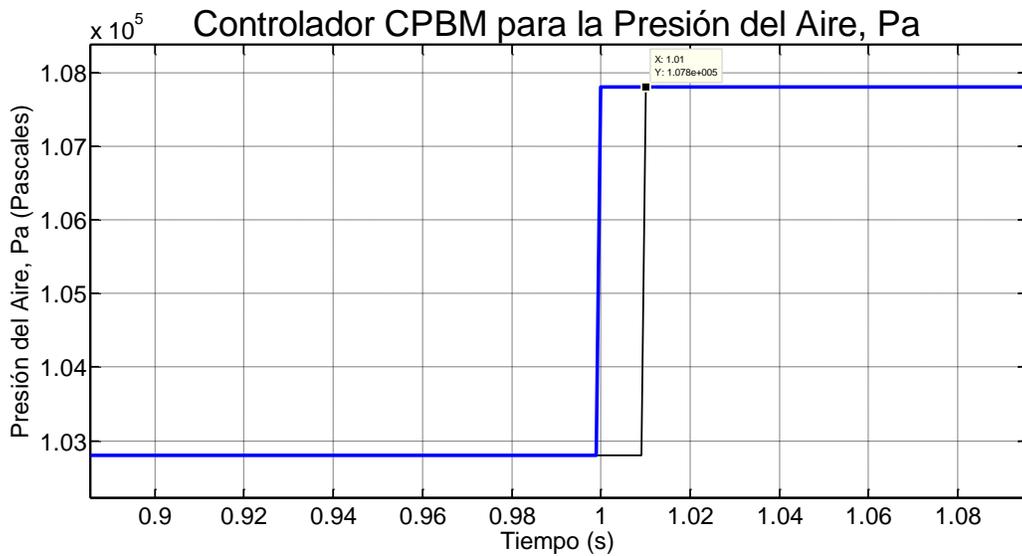


Figura 5. 30 Simulación del MPC para el control de la presión del aire, Pa.

Acercamiento.

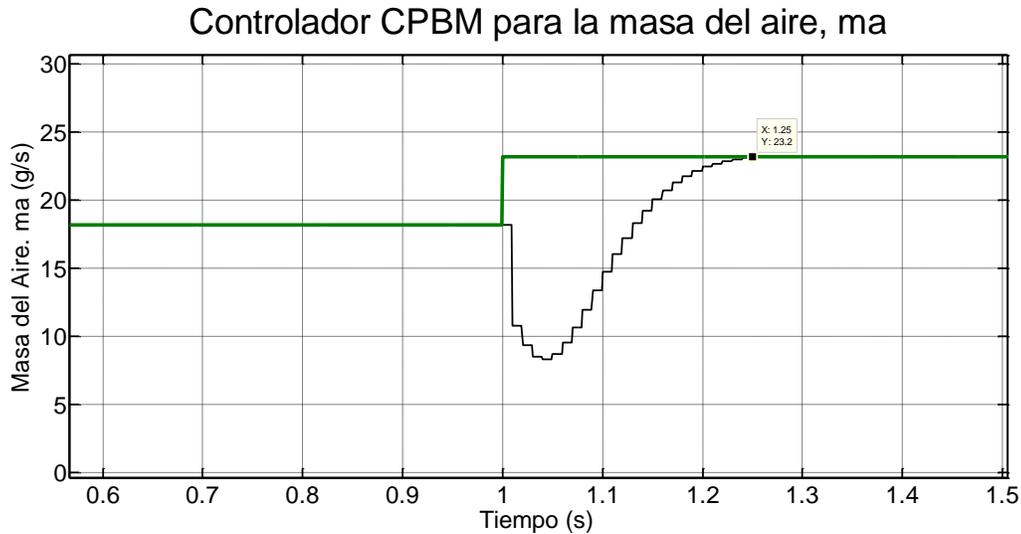


Figura 5. 31 Simulación del MPC para el control de la masa del aire, ma. Acercamiento.

Se observa en la figura 5.30 que la simulación del modelo propuesto alcanza el setpoint de Pa en un ciclo; comparado con el gráfico de la figura 5.26, se ve que el punto deseado se obtiene en 300 ciclos aproximadamente. Por otro lado, en la figura 5.31 se observa que la consigna de ma se alcanza en 25 ciclos; comparado con la simulación del modelo de referencia, figura 5.27, se puede apreciar que para alcanzar dicha consigna se tomó 100 ciclos aproximadamente.

Además de la muestra de las gráficas comparativas del modelo propuesto y el de referencia, se utilizó un indicador que nos permitió cuantificar la calidad de los resultados obtenidos. El índice seleccionado es el denominado VAF (Variance Accounted For), que representa la varianza en porcentaje entre dos señales temporales. Este índice es ampliamente utilizado en la literatura dentro del ámbito de identificación de sistemas dinámicos.

$$VAF = 100\% \left[1 - \frac{\text{var}(y - y')}{\text{var}(y)} \right]$$

Donde y e y' serán vectores en el caso monovariable y matrices en el caso multivariable. (García Nieto, 2007).

Los resultados obtenidos fueron:

VAF para Pa = 99.23 % y

VAF para ma= 93.99 %.

5.6.1 Validación de los modelos obtenidos

Se presenta a continuación un resumen de los valores de validación de los modelos obtenidos en este trabajo:

5.6.1.1 Validación del modelo multivariable identificado:

a). Simulación modelo identificado con estructura OE vs. datos medidos (figura 5.3):

Aproximación del ajuste para Pa = 89.40 %

Aproximación del ajuste para ma = 82.17 %

b). Análisis de residuos (ver figuras 5.5 a 5.8):

Correlación cruzada de la entrada EGR y ma: nivel de confianza 99%

Correlación cruzada de la entrada TGV y ma: nivel de confianza 99%

Correlación cruzada de la entrada EGR y Pa: nivel de confianza 99%

Correlación cruzada de la entrada TGV y Pa: nivel de confianza 99%

5.6.1.2 Validación de modelo RNA (figuras 5.12 a 5.16):

a). Gradiente del error: 1.2447 e-7

b). Regresión lineal, Entrenamiento R=1

c). Regresión lineal, Validación R=0.9745

d). Regresión lineal, Prueba R=0.8385

e). Regresión lineal, Promedio R=0.9589

5.7 Publicaciones

Se realizaron un par de publicaciones, la primera se presentó en la modalidad de póster en el 4o. Congreso Nacional de Ingeniería, organizado por la Universidad Autónoma de Querétaro. En él se hace una descripción compacta de los métodos paramétricos para identificar un motor diésel sobrealimentado. En el anexo 1.1 se puede ver una copia de la portada y resumen del artículo presentado y en el anexo 1.2 se muestra el reconocimiento.

La segunda publicación se presentó en la modalidad de ponencia en el Primer Congreso Nacional de Ingeniería de la Universidad Politécnica de Victoria. En ésta se hace una descripción rápida de los métodos paramétricos que mejor resultado entregaron en la identificación del motor diésel sobrealimentado y se proponen algunas mejoras. El modelo es más compacto y el porcentaje de aproximación es muy similar al de la publicación anterior. En el anexo 1.1 y 1.2 se puede ver una copia del artículo y del reconocimiento, respectivamente.

CAPÍTULO VI
CONCLUSIONES Y
TRABAJO A FUTURO

6.1 Conclusiones

En este trabajo se llevaron a cabo algunas propuestas del modelado de un Motor de Combustión Interna Diésel Sobrealimentado. De acuerdo a los objetivos planteados, se consideraron solo dos variables controladas: la presión del aire en el colector de admisión (P_a) y el gasto másico del aire admitido (m_a); y dos variables manipuladas: la posición de los elementos finales de control, válvula TGV y válvula EGR, respectivamente. Cabe mencionar que estos sensores y actuadores se encuentran presentes en los motores comerciales de este tipo. Se utilizaron métodos de identificación de sistemas para obtener modelos, entre ellos algunos métodos paramétricos que nos entregaron un modelo discreto y multivariable, que consistía de dos entradas y dos salidas, y con polinomios de segundo orden. La estructura con mejores resultados fue la OE (error en la salida). La simulación entregó aproximaciones del 89.4% y 82.17% para P_a -aire y m_a -aire, respectivamente. El modelo antes mencionado se tomó como base para diseñar algunos controladores. Debido a que se trataba de un sistema multivariable con una gran interdependencia entre sus dos variables a controlar, se determinó utilizar métodos de desacoplamiento de sistemas. En este caso el desacople fue parcial y previo a la aplicación de los controladores PID; como resultado, vimos que se pudo controlar, aunque la respuesta era muy lenta, requirió de muchos ciclos de procesamiento.

Como segunda alternativa se llevó a cabo un desacoplamiento completo del sistema y se desarrollaron dos controladores, utilizando un método analítico de diseño de sistemas de control en tiempo discreto. Los resultados fueron favorables con una respuesta rápida, aunque se apreciaba un sobretiro considerable.

En la tercera opción se implementó un Controlador Predictivo Basado en Modelos, uno de los controladores inteligentes con más difusión en el ámbito industrial, precisamente por sus buenos resultados. Este caso no fue la excepción y se pudo apreciar una respuesta rápida, con un control para la presión del aire, P_a , sin error apreciable a simple vista, y para la masa del aire, m_a , con una respuesta rápida y sobretiros muy moderados. Se utilizó un indicador, VAF, para determinar la varianza entre las señales, fueron para P_a : 99.23% y para m_a : 93.99%.

Una alternativa interesante fue el desarrollo de un modelo con RNA, debido a las características propias del sistema, no lineal y multivariable, las redes neuronales resultaron ser una buena alternativa. Los resultados fueron muy aceptables, no obstante que no se disponían de datos en la cantidad suficiente para realizar un entrenamiento adecuado. Este fue uno de los factores que impidieron que se desarrollara un controlador para este modelo de identificación.

El control eficiente de estas variables, P_a y m_a , permitirá cumplir de manera óptima con los requerimientos de las cartas del fabricante, contribuyendo a la disminución de las emisiones de contaminantes: Partículas: Humos + Hidrocarburos y Óxidos de Nitrógeno, y cumpliendo con las prestaciones demandadas por los usuarios.

6.2 Fortalezas y debilidades

Una de las principales fortalezas de este trabajo es la obtención de un modelo paramétrico muy compacto, apenas de segundo orden, lo que permite llevar a cabo diseño de controladores de muy diversa índole y simulaciones que demandan pocos recursos computacionales. Los modelos matemáticos generados se encuentran en tiempo discreto, lo que representa varias ventajas para su implementación en sistemas de control como μ controladores o FPGAs. El trabajo con base en este modelo no requiere de bancos de prueba ni recursos físicos, lo cual hace muy versátil su estudio y análisis. Otro punto fuerte es la adaptación de un Controlador Predictivo Basado en Modelos, siendo uno de los controladores inteligentes de más auge en la industria durante los últimos años, ya que su implementación es factible en equipos comerciales.

Una de las principales debilidades de este trabajo es que fue realizado tomando como base modelos aproximados, de tal manera que su implementación demandará pequeños ajustes para poderlo acoplar a un sistema físico.

Otro punto de mejora es que no se dispuso de un banco de pruebas para validar los resultados obtenidos.

6.3 Trabajo a futuro

Sin duda la implementación de este sistema en un motor de combustión interna diésel sobrealimentado es algo que podría ser de gran interés dados los resultados que se pudieron observar en la simulación.

Se pudo apreciar una conveniencia para realizar el modelado y control utilizando un sensor, m_{EGR} , de la masa de los gases de recirculación, en lugar de la presión del aire, P_a , se aclara que actualmente este sensor no se encuentra disponible en los motores comerciales de combustión interna de este tipo. Así que esta opción se presenta como un buen reto.

El desarrollo de un controlador con RNA dadas las características inherentes del proceso podría resultar en una alternativa muy interesante, principalmente en el control de la emisiones de los gases de escape, además de que permitiría manejar todas las variables relacionadas con el proceso de la combustión como entradas.

BIBLIOGRAFÍA

(EPA), A. E. (2000). *Environmental Protection Agency*. Recuperado el 10 de 11 de 2007, de <http://www.dieselnet.com/standards/us/hd.html>

(EPA), U. S. (2002). *Inventory of U.S. greenhouse gas emissions and sinks: 1990-2000*. EPA 430/R-02-003.

Agency, U. S. (1993). *National air quality and emissions trends report*. EPA 454/R-93-031.

Agrawal, A. K., Singh, S. K., Sinha, S., & Shukla, M. K. (2004). Effect of EGR on the exhaust gas temperature and exhaust opacity in compression ignition engines. *Sashana, India* , Vol. 29, Part 3, pp. 275-284.

Aguado Behar, A. (2000). *Temas de identificación y control adaptable*. La Habana, Cuba: Instituto de Cibernética, Matemática y Física.

Blasco, F. X. (1999). *Control predictivo basado en modelos mediante la incorporación de técnicas de optimización heurística. Aplicación a procesos no lineales y multivariables*. Valencia: UPV, Tesis Doctoral.

Bosch GmbH, R. (2005). *Diesel-engine Management*. Cambridge: Bentley Publishers, ISBN: 0-8376-1353-1.

Bristol, E. H. (1996). On a new measure of interaction for multivariable process control. *IEEE TRANS. ON AUTO. CONTROL, AC-11* , 133-134.

Camacho, E. F. (2004). *Control Predictivo : Pasado, presente y futuro*. Valencia: RIAL CEA-IFAC.

Ciclo teórico Motor CI. (Septiembre de 2010). Recuperado el 3 de Noviembre de 2014, de *Ciclo teórico Motor CI*: http://www.rooutek.com/iuti/pdf/ciclo_teorico.pdf

Clarke, D. M. (1987). *Generalizes Predictive Control-Part I*. Automática.

Creus, A. (2001). *Instrumentación Industrial*. Bogotá: Alfaomega, S.A.

Cutler, C. R. (1980). *Dynamic matrix control - a computer control algorithm*. San Francisco, CA, USA: Joint Automatic Control Conference (JACC).

Department of Energy, U. (Agosto de 2003). *FreedomCar and Vehicle Technologies Program, Just the Basics: Diesel Engine*. Recuperado el 2 de Octubre de 2014, de DOE Office of Energy Efficiency and Renewable Energy: http://www1.eere.energy.gov/analysis/pdfs/advanced_

Eberthardt, J. J. (2000). *The Diesel paradox: why dieselization will lead to cleaner air*. 6th Diesel Engine Emission Reduction (DEER) Workshop.

EPA, U. (Octubre de 2002a). *Environmental Protection Agency*. Recuperado el 10 de Noviembre de 2014, de A Comprehensive Analysis of Biodiesel Impacts on Exhaust Emissions: <http://www.epa.gov/otaq/models/analysis/biodsl/p02001.pdf>

EPA, U. (2002). *Inventory of U.S. greenhouse gas emissions and sinks*. USA: Environmental Protection Agency.

Ericson, C. (2009). *Model Based Optimization of a Complete Diesel Engine/SCR System*. Sweden: MEdia-Tryck, Lund 2009.

Fernandez, C. R. (2007). *Tesis Doctoral. Control Predictivo Basado en Modelos (CPBM) robusto con DBU*. Valencia: Universidad Politécnica de Valencia.

García Díaz, R. (2005). *Diccionario Técnico*. México, D.F.: Limusa.

García Nieto, S. J. (2007). *Identificación y Control Fuzzy en Motores Diésel Turboalimentados*. Hueva, España: XXXVIII Jornadas de Automática.

García, C. M. (1986). *Quadratic programming solution of dynamic matrix control (QDMC)*. Chemical Eng. Commun.

García, C. P. (1989). *Model predictive control: Theory and practice - a survey*. Automatica.

Genceli, H. N. (1993). *Robust stability analysis of constrained l_1 -norm model predictive control*. AIChE Journal.

Hernández López, L. (2006). *Predicción y optimización de emisores y consumo mediante redes neuronales en motores Diesel*. Valencia, España: Reverté.

Heywood, J. B. (1988). *Internal Combustion Engine Fundamentals*. New York: McGraw-Hill, Inc.

Hidráulicos, S. d. (s.f.). *ACUERDO-NOM-044-ECOL-10-FEB-03*. . Recuperado el 12 de 10 de 2007, de www.semarnat.gob.mx/leyesynormas/normasoficialesmexicanasvigentes/Atmosfera/ACUERDO-NOM-044-ECOL-10-FEB-03

Hooley's, R. (s.f.). *Wikipedia*. Recuperado el 10 de 6 de 2007, de Diesel_engine: http://en.wikipedia.org/wiki/Diesel_engine

J.J, H. (2000). *Tesis Doctoral: Modelado de la formación y emisión de contaminantes en sistemas de combustión*. Valencia, España: Universidad Politécnica de Valencia.

Juntadeandalucia. (2004). *Junta de Andalucía*. Recuperado el 3 de Octubre de 2014, de Principios de termodinámica de motores: http://www.juntadeandalucia.es/averroes/~23005153/d_tecnologia/LIBRO/pdf/termopri.pdf

Lavoie G., H. J. (1970). Experimental and theoretical study of nitric oxide formation in internal combustion engines. *Combustion Science and Technology* , Vol. 1, pp. 313-326.

Lee, S., Howlett, R., Walters, S., & Crua, C. (2001). *Fuzzy Logic and Neuro-fuzzy Modelling of Diesel Spray Penetration*. Brighton, UK: University of Brighton.

Ljung, L. (1994). *Modeling of Dynamic Systems*. Sweden: Prentice Hall.

Ljung, L. (1987). *System Identification*. USA: Prentice Hall.

López, G. M. (2006). *Universidad de Alcalá, Departamento de Electrónica.(Madrid)*. Recuperado el 7 de 2 de 2008, de www.depeca.uah.es/docencia/ING-ECA/ctr_avz/Identif.PDF

M., H. H. (1983). *Development and use of a spray combustion modeling to predict Diesel engine efficiency and pollutant emissions (Part I: combustion modeling)*. Bulletin of the JSME, Vol. 26, pp. 569-575.

Mann, J. W. (2011). *Twin-Turbocharged Diesel performance under snorkelling conditions*. London: Defence Services, UK.

Mark Hudson Beale, M. T. (2010). *Neural Network Toolbox 7, User's Guide*. USA: Math Works.

Marlin, T. (1995). *Process Control, Designing Processes and Control System for Dynamic Performance*. Mc Graw-Hill.

Miller, T. C., Jackson, M. A., Brown, A. J., & Wong, V. W. (1998). *Prevention of Air Pollution from Ships: Diesel Engine Particulate Emission Reduction via Lube-Oil-Consumption Control*. USA.

Obert, E. F. (1982). *Motores de Combustión Interna, Análisis y Aplicaciones*. México, D.F.: C.E.C.S.A.

Ogata, K. (1996). *Sistemas de Control en Tiempo Discreto*. Edo. de México: Prentice Hall Hispanoamericana, S.A.

Qin, S. J. (2003). A survey of industrial model predictive control technology. *A survey of industrial model predictive control technology* (págs. 733-764). Control Engineering Practice.

Qin, S. T. (1997). An overview of industrial model predictive control technology. *An overview of industrial model predictive control technology* (pág. 232.256). 5th Int. Conf. on Chemical Process Control.

Ramos Fernández, C. (2007). *Control Predictivo Basdo en Modelos (CPBM) robusto con BDU*. Valencia, España: isa.

Rao, C. V. (1998). *Optimization strategies for linear model predictive control*. 5th IFAC Symposium on Dynamics and Control of Process Systems (DYCOPS-5).

Richalet, J. A. (1976). *Algorithmic control of industrial processes*.

Richalet, J. R. (1978). *Model predictive heuristic control: Applications to insdustrial processes*. Automatica.

Richalet, J. S.-D. (1987). *Predictive functional control, application to fast and accurate robots*.

Rouhani, R. R. (1982). *Model algorithmic control: Basic properties*. Automatica.

Salcedo, J. M. (2000). *Control predictivo generalizado con índice de coste modular*. Terrassa, España: Seminario Anual de Automática.

Salcedo, J. V., Blasco, X., Martínez, M., & García, J. V. (2001). *Modelado y control en Simulink de un motor diesel sobrealimentado*. Barcelona, España: XXII Jornadas de Automática, UPV.

Salcedo, J. V.; Martínez, M. (2007). LPV identification of a turbocharged diesel engine. *Revista Applied Numerical Mathematics* , ISSN 0168-9274.

SENER. (2013). *Secretaría de Energía*. Recuperado el 11 de Noviembre de 2014, de Prospectiva de Petróleo Crudo y Petrolíferos 2013-2027: <http://www.energia.gob.mx/>

Stephanopoulos, G. (1984). *Chemical Process Control*. USA: Prentice Hall.

THAM, M. (1999). *MULTIVARIABLE CONTROL: AN INTRODUCTION TO DECOUPLING CONTROL*. ENGLAND: UNIVERSITY OF NEWCASTLE UPON TYNE.

Traver, M. L., Atkinson, R. J., & M., A. C. (1999). *Neural Network-Based Diesel Engine Emissions Prediction Using In- Cylinder Combustion Pressure*. Dearborn, Michigan: Emission Formation Processes in SI and Diesel Engines.

Z., B. (1992). Diesel combustion and emission predictive capability for use in cycle simulation. *SAE* , SAE paper 920462.

ANEXO 1

PUBLICACIONES

Anexo 1.1. Artículos

UNIVERSIDAD AUTÓNOMA DE QUERÉTARO
FACULTAD DE INGENIERÍA
Centro Universitario s/n Col. Las Campanas
Querétaro, Qro.
Tel. 1. 92.12.00 Ext. 6016 Y 6008



Identificación de un motor diesel sobrealimentado Identification of a turbocharged diesel engine

Ubaldo Javier Flora Velasco^{1,2}, Fernando Hernández Rosales², José Vicente Salcedo y M. Martínez⁴, Ricardo Chaparro Sánchez^{2,3}, Domingo Rangel Miranda^{3,5}

¹Universidad Tecnológica de Querétaro. Av. Pie de la cuesta no. 2501, Querétaro, México.

²Posgrado Interinstitucional de Ciencia y Tecnología (CIDESI), Pie de la Cuesta 32, Querétaro, México.

³Universidad Autónoma de Querétaro, Gabino Barreda s/n Centro Universitario, Querétaro, México.

⁴Universidad Politécnica de Valencia, Camino de Vera 14. Apdo. 22012 E-46071, Valencia, España.

⁵Centro de Física Aplicada y Tecnología Avanzada, Universidad Nacional Autónoma de México, Campus Juriquilla Querétaro, Querétaro, México.

RESUMEN. En este trabajo se presenta la propuesta de un modelo discreto multivariable simplificado de un motor de combustión interna diesel sobrealimentado. El modelo propuesto se obtuvo a partir de un modelo base, el cual fue desarrollado considerando los parámetros dinámicos que describen su funcionamiento, así como relaciones experimentales en un banco de pruebas. Para la identificación de los parámetros se utilizaron las estructuras ARMAX (Auto-regresivo con promedio móvil exógeno), OE (Error en la Salida), y mínimos cuadrados para obtener los parámetros del modelo discreto. Se consiguió un ajuste del 89.67% para la presión del aire en el colector de admisión (P-aire) y un 83.13% para el flujo másico de aire en la salida del compresor (ma-aire). Este modelo ayudará a conseguir un control óptimo de las variables P-aire y ma-aire que a su vez permitirá minimizar las emisiones contaminantes.

Palabras Clave – Modelación multivariable, motor diesel, motores sobrealimentados, identificación de parámetros, ARMAX, OE, modelo diesel discreto.

1. INTRODUCCIÓN

1.1. Antecedentes

En los últimos años ha ido en aumento la preocupación a nivel mundial de los temas relacionados con el calentamiento global, calidad del aire en las ciudades, lluvias ácidas y efecto invernadero, y desde luego sus repercusiones en la salud de la población y medio ambiente.

El gran incremento poblacional ha traído consigo el acelerado crecimiento de la industria para satisfacer sus demandas, como consecuencia se ha visto un aumento considerable en la fabricación de vehículos que consumen derivados del petróleo, tanto de carga ligera y como pesada. El impacto al medio ambiente ha sido considerable, debido a las emisiones contaminantes a la atmósfera tal como CO, CO₂, NO_x (NO y NO₂), HC, partículas (PM). Los vehículos automotores juegan un papel importante por la cantidad de ellos que circulan diariamente.



Modelado y Simulación de un Motor Diesel Sobrealimentado

Flora V. Ubaldo J.
UTEQ, Querétaro, México
uflora@uteq.edu.mx

Hernández R. Fernando
CIDESI, Querétaro, México
fhernandez@cidesi.mx

Chaparro S. Ricardo
UAQ, Querétaro, México
rchapa@uaq.mx

Rangel M. Domingo
UNAM, Querétaro, México
ranged@fata.unam.mx

Meléndez R. Manuel
UTEQ, Querétaro, México
mmelendez@uteq.edu.mx

RESUMEN

En este trabajo se presenta la propuesta de un modelo discreto multivariable simplificado de un motor de combustión interna diesel sobrealimentado. El modelo propuesto se obtuvo a partir de un modelo base desarrollado considerando los parámetros dinámicos que describen su funcionamiento, así como relaciones experimentales en un banco de pruebas. Para la identificación de los parámetros se utilizaron modelos paramétricos de identificación y mínimos cuadrados para obtener los parámetros del modelo discreto. Se consiguió un ajuste del 89.4% para la presión del aire en el colector de admisión (P-aire) y un 82.17% para el flujo másico de aire en la salida del compresor (ma-aire). Este modelo ayudará a conseguir un control óptimo de las variables P-aire y ma-aire que a su vez permitirá minimizar las emisiones contaminantes.

Palabras clave – Modelo discreto multivariable, motor diesel sobrealimentado, identificación de parámetros.

I. INTRODUCCIÓN

1.1. Antecedentes

En los últimos años ha ido en aumento la preocupación a nivel mundial de los temas relacionados con el calentamiento global, calidad del aire en las ciudades, lluvias ácidas y efecto invernadero, y desde luego sus repercusiones en la salud de la población y medio ambiente.

El gran incremento poblacional ha traído consigo el acelerado crecimiento de la industria para satisfacer sus demandas, como consecuencia se ha visto un aumento considerable en la fabricación de vehículos que consumen derivados del petróleo, tanto de carga ligera y como pesada. El impacto al medio ambiente ha sido considerable, debido a las emisiones contaminantes a la atmósfera tal como CO, CO₂, NOx (NO y NO₂), HC, partículas (PM). Los vehículos automotores juegan un papel importante por la cantidad de ellos que circulan diariamente.

La Secretaría de Medio Ambiente y Recursos Naturales ha publicado a través del diario oficial (10 de febrero de 2003) que podrán importarse los vehículos automotores equipados con motores Diesel siempre y cuando ostenten las especificaciones contenidas en las Normas de la Agencia de

Protección Ambiental de los Estados Unidos de América, denominadas EPA 1998 y EPA 2004 o en las Normas Europeas denominadas Euro III y Euro IV (Semamat, 2003)

La EPA ha provisto de estándares para vehículos diesel de carga pesada. Los parámetros de emisión permitidos del 2010 en adelante (g/bhp-hr): HC:0.14, CO:15.50, NOx: 0.20, PM:0.01, (EPA, 2002).

Cada vez es más difícil por parte de los fabricantes de vehículos cumplir con las restricciones marcadas por las autoridades ambientales, por lo que día con día utilizan la tecnología de vanguardia para obtener modelos más exactos de los motores de combustión interna que les permitan optimizarlo.

1.2. Estado del arte

Enseguida se comentan algunos estudios relacionados con este tema, los cuales permitirán conocer las tendencias actuales en este campo de investigación.

J Wahlström et. al (2011) desarrollaron, parametrizaron y validaron el modelo de un motor diesel sobrealimentado con turbina de geometría variable (VGT) y recirculación de gases de escape (EGR). Dicho modelo se desarrolló en Simulink de Matlab y los parámetros fueron estimados utilizando técnicas de optimización de mínimos cuadrados. La validación del modelo presentó un error medio del 5.8 por ciento en las variables medidas.

J W Mann (2011) realizó un análisis del desempeño de un motor diesel con turboalimentación dual en aplicación submarina, comparándolo con otros tipos. Encontró que el motor turboalimentado presentaba mayores variaciones en su desempeño con un consumo específico de combustible marginalmente mejor que un motor superalimentado aunque, este último, más estable a las variaciones de entrada. El motor con doble turboalimentación fue menos estable que el de turboalimentación simple, pero ofreció un mejor consumo de combustible, mayor torque y potencia, aunque mayor inestabilidad en la velocidad.

Técnicas de lógica difusa y Neuro-Fuzzy fueron empleadas por Lee et. al (2005) para modelar el comportamiento de la atomización del diesel y así mejorar la mezcla de aire-combustible con la consecuente disminución de emisiones contaminantes. Se utilizó la medición de presión en el cilindro, la densidad del aire y temperatura como entradas

principales, y la longitud de penetración como la salida. Los resultados conseguidos arrojaron un coeficiente de correlación de 0.997, lo que significa que el modelo describió al proceso en un 99.7%.

También considerando el trabajo de Avinash et. al (2004), la EGR (Recirculación de los gases de escape) se presenta como una alternativa para disminuir las emisiones contaminantes. En los motores diesel la formación de NOx está fuertemente relacionada la temperatura de la cámara de combustión, sobre todo cuando la temperatura rebasa los 2000 K. Se concluye que el EGR de 0-21% favorece el decremento de la temperatura de los gases de escape con la consecuente disminución de NOx.

Salcedo et. al (2001) desarrollaron un modelo lineal multivariable de un motor diesel sobrealimentado y con EGR. Aplicando métodos de identificación de sistemas y tomando como base el modelo descrito en el punto 2.3, donde se toman como entradas la apertura de las válvulas TGV y EGR, y como salidas Pa (Presión en el colector de admisión) y ma (Gasto másico entregado por el compresor), se obtiene un modelo continuo y multivariable:

$$G_{ij}(s) = \begin{bmatrix} \frac{-379(1.15s+1)}{(0.73s+1)(0.17s+1)} & \frac{-35.7(-20s+1)}{(s+1)(0.1s+1)} \\ \frac{6.5 \cdot 10^{-4}}{(0.2s+1)} & \frac{-9.1 \cdot 10^{-4}}{(0.2235s+1)} \end{bmatrix} \quad (1)$$

Es un modelo sencillo donde las funciones de transferencia son de primero y segundo orden.

II. IDENTIFICACIÓN Y MODELO DEL MOTOR DIESEL SOBREALIMENTADO

2.1. El Motor Diesel Sobrealimentado

Dentro de los motores diesel el sobrealimentado con EGR es de los más utilizados, por las prestaciones que ostenta. El motor diesel con turbocompresor en su forma básica está compuesto de los elementos mostrados en la figura 1, los cuales se describen a continuación (Salcedo et. al 2001):

a) *Compresor*. Este dispositivo tiene la función de incrementar la presión del aire admitido, haciendo posible la alimentación de una mayor cantidad de aire fresco hacia el interior de los cilindros del motor.

b) *Interenfriador (Intercooler)*. Consiste en un intercambiador de calor, cuya finalidad es enfriar el aire que sale del compresor antes de ser ingresado a los cilindros, a menor temperatura disminuye la densidad por lo que una mayor cantidad se podrá introducir en los cilindros.

c) *Colector de admisión*. Se puede ver como la parte del proceso donde se lleva a cabo la mezcla del aire saliente del interenfriador y de los gases recirculados desde el escape (EGR).

d) *Colector de escape*. Ensanchamiento existente a la salida de los cilindros en el que se acumulan de forma temporal los gases de escape, y que conecta con la turbina y con el EGR.

e) *Circuito de EGR*. Es un tramo de tubo con una válvula de apertura variable (válvula de EGR) que conecta el colector de escape con el de admisión. A través de este arreglo mecánico se lleva a cabo la recirculación de los gases de escape hacia el colector de admisión (EGR).

f) *Turbina*. Es una máquina térmica que utiliza la temperatura y presión de los gases de escape para generar la energía mecánica y mover el compresor.

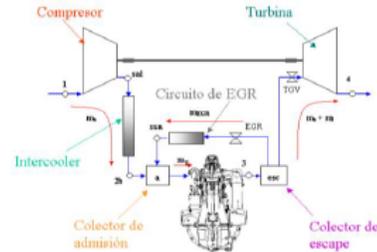


Fig. 1. Motor diesel con turbocompresor, Salcedo et. al (2001).

2.2. Identificación de Sistemas

La identificación de sistemas consiste en obtener de forma experimental un modelo que reproduzca el proceso con suficiente exactitud para los fines deseados, tomando en cuenta las características dinámicas del mismo (López, 2008). Para la identificación de sistemas se suele seguir algún procedimiento como el presentado en la figura 2.

a) *Recopilación y análisis de datos*. En esta etapa se recaba la información de las entradas y salidas del sistema. Para que la información de salida sea útil, se debe excitar el sistema con una señal de entrada, las cuales pueden ser ruido analógico o secuencias binarias pseudo-aleatorias (SBSA). Enseguida se preparan los datos, se lleva a cabo una depuración en la que se eliminan ruidos indeseados o algún tipo de anomalía en los datos.

b) *Selección de la estructura del modelo*. Existen varios tipos de modelos paramétricos estándar que han sido ampliamente probados, entre los cuales se encuentran: ARX (Auto-regresivo y variable exógena), OE (Error en la Salida), ARMAX (Auto-regresivo con promedio móvil exógeno), BJ (Box Jenkins). En la figura 3 se presentan los modelos ARMAX y OE, donde q^{-1} es el operador retardo, la entrada del sistema es $u(t)$; $e(t)$ es el ruido de entrada y la salida de interés es $y(t)$.

c) *Selección del modelo de ajuste de parámetros*. En seguida se procede a la estimación de los parámetros de la estructura que mejor ajustan la respuesta del proceso.

d) **Obtención del modelo y validación.** Una vez que se ha obtenido el modelo, el paso final consiste en determinar si dicho modelo satisface el grado de exactitud necesario para la aplicación. En caso de que no sea válido se deben revisar los incisos a, b y/o c, según sea el caso, y determinar si los datos proporcionan suficiente información de la dinámica del proceso, si la estructura del modelo seleccionada da una buena descripción o si el criterio de ajuste es el adecuado.

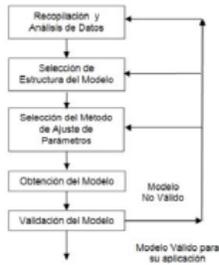


Fig. 2. Metodología de identificación.

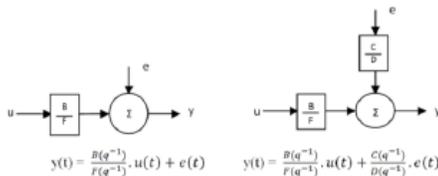


Fig. 3. Estructura OE (izquierda) y Estructura BJ (derecha)

2.3 Modelo de referencia en Simulink

El modelo que se utilizó como base para este trabajo es el desarrollado por el Departamento de Motores Térmicos de la UPV (Salcedo, et. al, 2001). Dicho modelo ha sido diseñado con base en la aplicación de ecuaciones físicas, de balances de materia y energía, así como relaciones experimentales obtenidas por ajuste de datos obtenidos en el banco de pruebas.

Se programaron en Simulink de MatLab los bloques que contienen las ecuaciones que describen el comportamiento de cada uno de los elementos (véase la figura 1) que forman parte del motor de combustión interna diesel. Para llevar a cabo la simulación es posible modificar las variables siguientes:

1. Régimen de giro del motor (N)
2. Gasto másico de combustible
3. Apertura EGR
4. Apertura TGV
5. Temperatura a la salida del intercooler (T2b)
6. Temperatura del aire exterior (Ti)

Las variables de salida más importantes que proporciona este modelo son:

1. Gasto másico de aire entregado por el compresor (ma)
2. Presión en el colector de admisión (Pa)
3. Gasto másico recirculado por EGR (mEGR)

2.4. Desarrollo del modelo propuesto

La identificación del proceso se llevó a cabo utilizando el *System Identification Toolbox 7.3 de MatLab*. Los datos se obtuvieron a partir del modelo descrito en el punto 2.3. Para este trabajo se utilizó un modelo multivariable como el que se muestra en la figura 4. Se consideraron las variables TGV y EGR como entradas simultáneas del modelo y como salida P-aire, solamente, después se consideraron las mismas entradas y la salida ahora fue ma-aire. Se observó una mejor aproximación para esta disposición, comparado con el resultado de configuraciones diferentes tal como el de SISO (una entrada una salida).

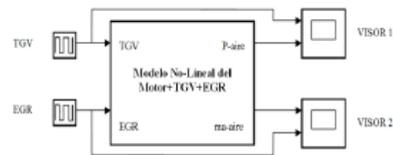


Fig. 4. Modelo compacto utilizado para la identificación del sistema.

La entrada de excitación utilizada fue una Secuencia Binaria Seudo-Aleatoria para TGV y EGR. Se tomaron 50,000 muestras con un periodo de muestreo $T_s=0.01s$. El cambio de valor de las señales de entrada se limitó a un mínimo de 10 segundos para dar oportunidad que el sistema respondiera. En la fase de análisis y depuración de datos se desecharon los primeros 5,500, el lote de datos escogido se dividió en dos, la primera mitad se utilizó para la obtención del modelo y el resto se dejó para la validación del mismo.

4. RESULTADOS Y DISCUSIÓN

Una de las estimaciones se llevó a cabo con la estructura BJ. La validación del modelo se hizo comparando la salida del modelo obtenido con los datos medidos, el resultado se presentan en la figura 5.

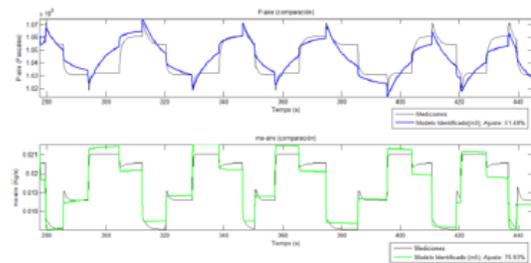


Fig. 5. Comparación entre el modelo obtenido con la estructura BJ y los datos medidos.

Se puede ver una aproximación con un 51.48% para la Presión de aire (P-aire) y un 75.93% para el flujo másico del aire (ma-aire).

La segunda estimación se realizó con la estructura OE (error en la salida). La validación se realizó comparando la salida del modelo obtenido con los datos medidos, el resultado se presenta en la figura 6. Las aproximaciones conseguidas fueron del 89.4% y 82.17% para P-aire y ma-aire, respectivamente, además se observa que el error va disminuyendo a medida que transcurre el tiempo. El modelo discreto obtenido se presenta en la figura 7.

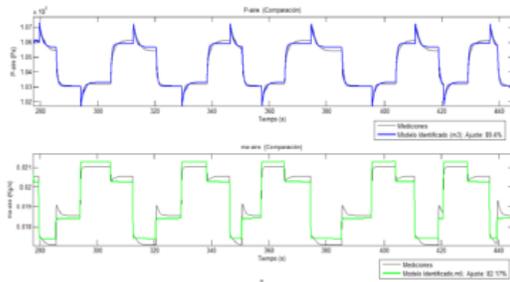


Fig. 6. Comparación entre el modelo obtenido con la estructura del Error en la Salida y los datos medidos.

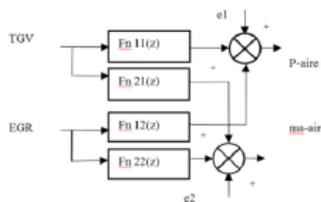


Fig. 8. Modelo multivariable del motor de combustión Interna Diesel Sobrealimentado.

$$Fn11(z) = \frac{-19.69q^{-1} + 19.69q^{-2}}{1 - 1.977q^{-1} + 0.977q^{-2}} \quad (2)$$

$$Fn12(z) = \frac{106.3q^{-1} - 106.6q^{-2}}{1 - 1.747q^{-1} + 0.7492q^{-2}} \quad (3)$$

$$Fn21(z) = \frac{3.884e^{-2}q^{-1} - 3.884e^{-1}q^{-2}}{1 - 1.869q^{-1} + 0.869q^{-2}} \quad (4)$$

$$Fn22(z) = \frac{-0.0001453q^{-1} + 0.0001453q^{-2}}{1 - 1.852q^{-1} + 0.8523q^{-2}} \quad (5)$$

La estructura de OE favoreció notablemente los resultados de la identificación, se consiguió una mejora de más del 50% en Pa-aire y aproximadamente del 10% en el caso de ma-aire, como puede verse en las fig. 5 y 6, respectivamente. Además, se aclara que el grado de los modelos obtenidos con la estructura BJ fue considerablemente mayor.

4. CONCLUSIONES

El objetivo de este trabajo se cumplió al conseguir aproximaciones superiores al 80% de ajuste, considerando que el proceso es multivariable y no lineal.

El tipo de modelo que entregó una mejor aproximación fue el del Error en la Salida, consiguiendo un ajuste del 89.4% para P-aire y del 82.17% ma-aire.

Este procedimiento se puede llevar a cabo para la identificación en laboratorio de un Motor de Combustión Interna Diesel Sobrealimentado.

El modelo obtenido se podrá utilizar para el diseño de controladores que permitan regular de manera eficiente la apertura de las válvulas TGV y EGR, manteniendo las variables P-aire y ma-aire en los niveles óptimos marcados en los mapas de fabricación, mismos que están calibrados de acuerdo a los niveles de emisiones contaminantes permitidos por las leyes ambientales.

5. REFERENCIAS

Aguado B. A., 2000, Temas de identificación y control adaptable, La Habana, ICDMAF, 313p.

Avinash Kamur Agrawal, Shrawan Kumar Singh, Shailendra Sinha y Mritunjay Kumar Shukla, 2004, Effect on the exhaust gas temperature and exhaust opacity in compression ignition engines, Sadhana 29(3): 275-284.

EPA (United States of Environmental Protection Agency), 2000, Applicability and Test Cycles. <http://www.dieselnet.com/standards/us/hd.html>, Consulta hecha el 22/Ago/2014.

Lee S. H., Howlett R.J., Walters S.D. y Drua C., 2005, Fuzzy Logic and Neuro-fuzzy Modelling of Diesel Spray Penetration, In: KES 2005, 14-16 September 2005, Melbourne, Australia.

López M. E., 2008, Identificación al modelado de un motor de continua, Universidad de Alcalá, Madrid. www.depeca.uah.es/docencia/ING-ECA/ctr_avz/Identif.PDF, Consulta hecha el 7 Enero de 2008.

Mathworks Inc., 2009, Manual de referencia de MatLab.

Miller T.C., Jackson M.A., Brown A.J. y Wong V.W., 1997, Prevention of Air Pollution from Ships: Diesel Engine Particulate Emission Reduction via Lube-Oil-Consumption Control, ASNE Environmental Symposium.

Salcedo J.V., Blasco X., Martínez M. y García J.V., 2001, Modelado y control en Simulink de un motor diesel sobrealimentado, in: XXII Jornadas de Automática, España.

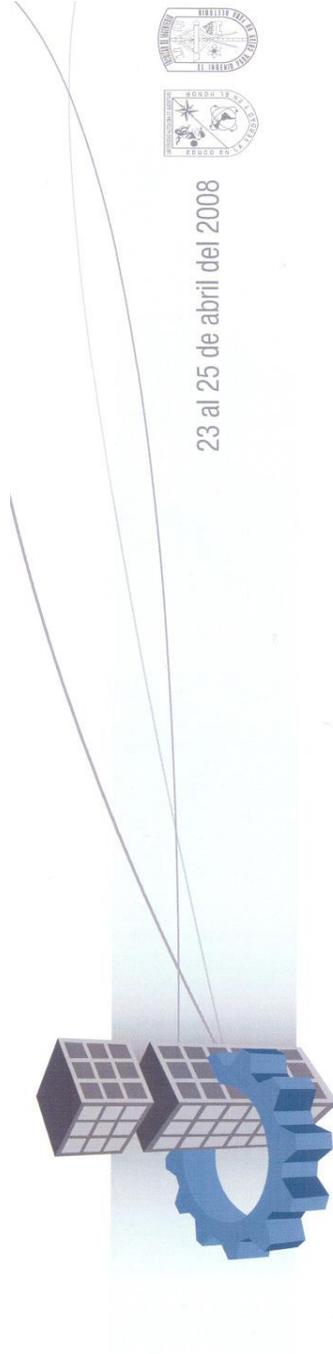
Salcedo J.V. y Martínez M., 2007, LPV identification of a turbocharged diesel engine, Applied Numerical Mathematics, (doi:10.1016/j.apnum.2007.09.005).

SEMARNAT (Secretaría del Medio Ambiente y Recursos Hidráulicos), 2003, Acuerdo-NOM-044-ECOL-10-FEB-03, www.semarnat.gob.mx/leyesyordinas/normasoficialesmexicanasvigentes/Atmsfera/ACUERDO-NOM-044-ECOL-10-FEB-03.pdf, Consulta hecha el 15 Octubre de 2007.

Johan Wahlström and Lars Eriksson, Modelling diesel engines with a variable-geometry turbocharger and exhaust gas recirculation by optimization of model parameters for capturing non-linear system dynamics, 2011, Proceedings of the Institution of mechanical engineers. Part D, journal of automobile engineering, (225), 7, 960-986. <http://dx.doi.org/10.1177/0954407011398177>

J W Mann, BMT Defence Services, UK, 2011, Twin-Turbocharged Diesel Performance under Snorkelling Conditions. BMT Defence Services Ltd.

Anexo 1.2 Reconocimientos



4º CONGRESO
INTERNACIONAL DE INGENIERÍA

La UNIVERSIDAD AUTÓNOMA DE QUERÉTARO

a través de la FACULTAD DE INGENIERÍA otorga el presente reconocimiento a

**U. FLORA, F. HERNÁNDEZ, J. V. SALCEDO, R. CHAPARRO,
D. RANGEL**

por haber participado en el 4º Congreso Internacional de Ingeniería
con el póster

Identificación de un motor diesel sobrealimentado

Dr. Gilberto Herrera Ruiz
Director
Facultad de Ingeniería

Dr. Rufino Nava Mendoza
Coordinador de la sesión de pósters



LA UNIVERSIDAD POLITÉCNICA DE VICTORIA
Se complace en otorgar el presente:

Reconocimiento

A los Autores:

Ubaldo Javier Flora Velazco, Fernando Hernández Rosales, Ricardo Chaparro Sánchez, Domingo Rangel Miranda y Manuel Meléndez Romero

Por sustentar la conferencia

“Modelado y simulación de un motor de diésel sobrealimentado”

En el marco del Primer Congreso Nacional de Ingeniería
CONNAI 2014

Mtra. Sonia Maricela Sánchez Moreno
RECTORA



Cd. Victoria, Tamaulipas, 18 y 19 de septiembre de 2014

ANEXO 2

PROGRAMAS

Anexo 2.1 Programa para Identificación del sistema.

```
tic
%Programa para Identificar un Motor CI Diésel
clc
clear all
format long
load ('C:\work2006b_120708\ID_DATA\DIESEL_IO')
LPa=length(Pa);
%Variables: EGR, TGV, Pa, ma
Pa1=Pa(5500:50001);
ma1=ma(5500:50001);
TGV1=TGV(5500:50001);
EGR1=EGR(5500:50001);
Pa_vd=Pa(27751:50001);
ma_vd=ma(27751:50001);
TGV_vd=TGV(27751:50001);
EGR_vd=EGR(27751:50001);
Pa_2=Pa(5500:27750);
ma_2=ma(5500:27750);
TGV_2=TGV(5500:27750);
EGR_2=EGR(5500:27750);
who
Ts=0.01;
diésel = iddata([Pa1,ma1],[TGV1,EGR1],Ts);
diésel.InputName = {'TGV';'EGR'};
diésel.OutputName = {'P-aire';'ma-aire'};
diésel_vd1=iddata([Pa_vd],[TGV_vd,EGR_vd],Ts);
diésel_vd2=iddata([ma_vd],[TGV_vd,EGR_vd],Ts);
diésel_id1=iddata([Pa_2],[TGV_2,EGR_2],Ts);
diésel_id2=iddata([ma_2],[TGV_2,EGR_2],Ts);
diésel_vd3=iddata([Pa1],[TGV1,EGR1],Ts);
m3=oe(diésel(5500:27750,'P-aire',:),'nb',...
[2 2],'nf',[2 2],'nk',[1 1]);
m5=oe(diésel(5500:27750,'ma-aire',:),'nb',...
[2 2],'nf',[2 2],'nk',[1 1]);
compare(diésel(27751:50001),m3,m5)
toc
```

Resultado:

Discrete-time IDPOLY model: $y(t) = [B(q)/F(q)]u(t) + e(t)$

$$B1(q) = -19.69 q^{-1} + 19.69 q^{-2}$$

$$B2(q) = 106.3 q^{-1} - 106.6 q^{-2}$$

$$F1(q) = 1 - 1.977 q^{-1} + 0.9769 q^{-2}$$

$$F2(q) = 1 - 1.747 q^{-1} + 0.7492 q^{-2}$$

Estimated using PEM from data set diésel_vd1

Loss function 27819.4 and FPE 27839.4

Sampling interval: 0.01

Discrete-time IDPOLY model: $y(t) = [B(q)/F(q)]u(t) + e(t)$

$$B1(q) = 3.884e-005 q^{-1} - 3.884e-005 q^{-2}$$

$$B2(q) = -0.0001453 q^{-1} + 0.0001453 q^{-2}$$

$$F1(q) = 1 - 1.869 q^{-1} + 0.8686 q^{-2}$$

$$F2(q) = 1 - 1.852 q^{-1} + 0.8523 q^{-2}$$

Estimated using OE from data set z

Loss function 6.67955e-008 and FPE 6.68436e-008

Sampling interval: 0.01

Created: 07-Mar-2012 12:05:43

Last modified: 01-May-2013 22:30:34

Anexo 2.2 Programa para entrenar la RNA.

```
%MODELO DE RNA_8
%8 entradas, 4 salidas y una capa oculta de 8 neuronas.
%Correr previamente el archivo "NORMALIZACION_DATOS_16.m"
%clc;
net=network;
net.numlayers=1;
%Inputs
p=E1;
t=S1;
net=newff(p,t,8,{'logsig','purelin'}); %NO. NEURONAS CAPA OCULTA:8
net.trainParam.lr=0.02; % RAZON DE APRENDIZAJE
net.trainParam.epochs=200; %ITERACIONES
net.trainParam.goal=0.00000001; % ERROR
net=init(net); %INICIA PESOS ALEATORIAMENTE
net=train (net,p,t);
%prueba=sim(net,p1); comando para prueba de la RNA
```