

**PONTIFICIA UNIVERSIDAD
CATÓLICA DEL PERÚ**

Escuela de Posgrado



Desarrollo de un sistema de control avanzado basado en redes
neuronales artificiales de una turbina de gas

Tesis para obtener el grado académico de Maestro en Ingeniería de
Control y Automatización que presenta:

Salvador Yawar Yance Morales

Asesor:

D.Sc Raúl Rivas Pérez

Lima, 2025


Informe de Similitud

Yo, Rivas Pérez Raúl, docente de la Escuela de Posgrado de la Pontificia Universidad Católica del Perú, asesor de la tesis titulada Desarrollo de un sistema de control avanzado basado en redes neuronales artificiales de una turbina de gas, del autor Yance Morales, Salvador Yawar, dejo constancia de lo siguiente:

- El mencionado documento tiene un índice de puntuación de similitud de 9%. Así lo consigna el reporte de similitud emitido por el software *Turnitin* el 10/12/2025.
- He revisado con detalle dicho reporte y la Tesis o Trabajo de investigación, y no se advierte indicios de plagio.
- Las citas a otros autores y sus respectivas referencias cumplen con las pautas académicas.

Lugar y fecha:

San Miguel - Lima, 10 de diciembre del 2025

Apellidos y nombres del asesor / de la asesora: Rivas Pérez Raúl	
Pasaporte: E476217	Firma 
ORCID: 0000-0002-4639-4274	

Dedicatoria

Esta tesis está dedicada a mi familia por su apoyo incondicional ante los retos y dificultades, en especial a mi amada hija Isabella.



Resumen

En el presente trabajo se estudia el tema de la aplicación de las redes neuronales artificiales (RNA) para el modelado y control de turbinas de gas (TG) utilizadas en la industria en la generación eléctrica. Los modelos obtenidos basados en RNA fueron desarrollados en la plataforma MATLAB a partir de datos operacionales reales de una turbina de gas de un solo eje y ciclo simple, que conduce un generador eléctrico, demostrando la capacidad que tienen las RNA para capturar las dinámicas no lineales complejas de este tipo de sistemas. Se exploró el uso de las RNA dinámicas con arquitectura NARX por las ventajas que ofrecen para el manejo de datos en series de tiempo y por sus antecedentes de éxito en la literatura revisada. En este trabajo los modelos NARX fueron diseñados para comportamientos transitorios durante los procesos de arranque y de demanda de potencia. Los resultados obtenidos demuestran que las RNA tienen suficiente precisión y confiabilidad para la identificación y modelado de las TG.

Para el diseño de los controladores basados en RNA, se implementó en Simulink-MATLAB, el modelo de una TG de un solo eje y de ciclo simple para la generación eléctrica fundamentado en el modelo matemático de Rowen, el cual ha sido utilizado para estudios de comportamientos dinámicos de turbinas de gas en múltiples investigaciones. La variable controlada es la velocidad de rotación de la TG, la cual determina la potencia mecánica de generación. Los controladores diseñados fueron: un controlador predictivo basado en una RNA (RNA-MPC), un controlador fundamentado en linealización por retroalimentación (NARMA-L2), y un controlador proporcional-integral-derivativo (PID) como referencia para propósitos comparativos. Los parámetros relacionados para todos los controladores se han ajustado según los requisitos propuestos de diseño. Se demostró que los controladores basados en RNA ofrecen un mejor desempeño que los controladores convencionales. Se destaca el controlador NARMA-L2 por su desempeño superior. Además, se comprobó que un buen modelado de la turbina asegura que estos controladores tengan una respuesta más rápida y precisa. Por consiguiente, los controladores basados en RNA pueden ser considerados como una alternativa confiable frente a metodologías convencionales para el control de plantas industriales complejas como son las TG.

Índice

Resumen	i
Índice	ii
Índice de figuras	iv
Índice de Tablas	ix
Nomenclatura	x
Introducción	1
Capítulo 1: Estado del arte	4
1.1 Motivación de la investigación	4
1.2 Las Turbinas de Gas	6
1.3 Ciclo Brayton	7
1.4 Las TG para la generación eléctrica	10
1.5 Las TG en Perú	14
1.6 Identificación, modelado y control de una TG	15
1.7 Modelo de Rowen para turbinas de gas	21
1.8 Conclusiones	22
Capítulo 2: Marco Teórico	24
2.1 Controlador PID	24
2.2 Las redes neuronales artificiales (RNA)	26
2.2.1 El modelo NARX	27
2.3 Controlador predictivo basado en redes neuronales artificiales (RNA-MPC) ..	29
2.4 Controlador de linealización por retroalimentación (NARMA-L2)	33
2.5 Conclusiones	37
Capítulo 3: Identificación basada en RNA de una TG	38
3.1 Las TG como objeto de control automático	38
3.2 Método para el modelado	39
3.3 Variables fundamentales del proceso	40
3.4 Identificación de la TG	46
3.4.1 Identificación de la TG durante el arranque	48
3.4.1.1 Entrenamiento del modelo NARX de la TG durante el arranque	52
3.4.1.2 Validación del modelo	56
3.4.2 Identificación de la TG durante la demanda de potencia	58
3.4.2.1 Entrenamiento del modelo NARX de la TG durante la demanda de potencia	61

3.4.2.2 Validación del modelo	65
3.5 Conclusiones	67
Capítulo 4: Desarrollo de controladores basados en RNA para el control de la velocidad de una TG	68
4.1 Sistema de control de la TG.....	68
4.2 Fundamentación de la ley de control a utilizar (RNA)	78
4.3 Controlador predictivo basado en RNA (RNA-MPC).....	80
4.3.1 Diseño del controlador RNA-MPC.....	81
4.3.1.1 Identificación del sistema MPC basado en una RNA	82
4.3.1.2 Ajuste de los parámetros del controlador RNA-MPC	87
4.3.2 Simulación del controlador RNA-MPC	87
4.4 Controlador de linealización por retroalimentación (NARMA-L2).....	91
4.4.1 Diseño del controlador NARMA-L2	91
4.4.2 Simulación del sistema de control de la TG con el controlador NARMA-L2 ..	96
4.5 Controlador PID	99
4.5.1 Diseño del controlador PID	99
4.5.2 Simulación del sistema de control de la TG con controlador PID	101
4.6 Comparación del performance de los controladores diseñados	103
4.7 Conclusiones	109
Capítulo 5: Propuesta de implementación del controlador avanzado basado en RNA	111
5.1 Hardware del sistema	111
5.2 Programación del controlador lógico programable.....	112
5.3 Conclusiones	114
Conclusiones generales	115
Recomendaciones.....	117
Referencias Bibliográficas	119
Anexos	127
A. Códigos elaborados en MATLAB	127

Índice de figuras

Figura 1.1. Esquema típico de una turbina de gas [13].	7
Figura 1.2 Aplicación de la primera ley de la termodinámica del Ciclo Brayton [13].	8
Figura 1.3. Principales componentes de una TG [13].	11
Figura 1.4. Esquema de un sistema de cogeneración basado en una turbina de gas [13].	12
Figura 1.5. Representación matemática simplificada del sistema de control de una TG para estudios dinámicos [17, 18].	23
Figura 2.1. Diagrama de bloques del sistema de control con estructura paralela del PID [47].	25
Figura 2.2. Arquitectura de una RNA [54].	27
Figura 2.3. Estructura de la red NARX [57].	28
Figura 2.4. Proceso de entrenamiento del controlador MPC [57].	31
Figura 2.5. Estructura del modelo basado en una RNA [57].	32
Figura 2.6. Arquitectura del sistema de control basado en una RNA con un controlador MPC.	33
Figura 2.7. Estructura de la RNA NARMA-L2 [57].	35
Figura 2.8. Diagrama de bloques del controlador NARMA-L2 [57].	36
Figura 2.9. Estructura del controlador neuronal NARMA-L2 [57].	37
Figura 3.1. Método para el diseño sistemático de un modelo NARX [14].	40
Figura 3.2. Esquema del turbogenerador Centaur 50 típico [71].	41
Figura 3.3. Partes principales de la turbina Centaur 50 [71].	42
Figura 3.4. Proceso de combustión típico [71].	42
Figura 3.5. Ubicación de las variables de la TG.	44
Figura 3.6. Mapa de calor de correlación de Pearson de las variables seleccionadas.	45
Figura 3.7. Mapa de calor de correlación de Spearman de las variables seleccionadas.	46
Figura 3.8. Comportamiento de las variables mf y $T1$ durante el arranque de la TG.	50
Figura 3.9. Comportamiento de las variables Ngp y $T5$ durante el arranque de la TG.	50
Figura 3.10. Estructura de lazo cerrado del modelo NARX.	51
Figura 3.11. Diagrama de bloques del modelo NARX completo.	52

Figura 3.12. Resultados del entrenamiento del modelo NARX1 (Serie 1).....	52
Figura 3.13. Performance de validación del modelo NARX1 (Serie 1).....	53
Figura 3.14. Regresión del modelo NARX1 (Serie1).....	53
Figura 3.15. Respuesta de salida del modelo NARX1 (Serie 1).....	54
Figura 3.16. Resultados del entrenamiento del modelo NARX2 (Serie 1).....	54
Figura 3.17. Performance de validación del modelo NARX2 (Serie 1).....	55
Figura 3.18. Regresión del modelo NARX2 (Serie 1).....	55
Figura 3.19. Respuesta de salida del modelo NARX2 (Serie 1).....	56
Figura 3.20. Respuesta de la velocidad de rotación Ngp de la TG durante el arranque.....	57
Figura 3.21. Respuesta de la temperatura de los gases de escape $T5$ de la TG durante el arranque.....	57
Figura 3.22. Comportamiento de la mf durante la demanda de potencia.....	59
Figura 3.23. Comportamiento de la $T1$ durante la demanda de potencia.	59
Figura 3.24. Comportamiento de la Ngp durante la demanda de potencia.	60
Figura 3.25. Comportamiento de la $T5$ durante la demanda de potencia.	60
Figura 3.26. Comportamiento de la potencia aportada al sistema.	60
Figura 3.27. Resultados del entrenamiento del modelo NARX1 (Serie 2).....	61
Figura 3.28. Performance de validación del modelo NARX1 (Serie 2).....	62
Figura 3.29. Regresión del modelo NARX1 (Serie2).....	62
Figura 3.30. Respuesta de salida del modelo NARX1 (Serie 2).....	63
Figura 3.31. Resultados del entrenamiento del modelo NARX2 (Serie 2).....	63
Figura 3.32. Performance de validación del modelo NARX2 (Serie 2).....	64
Figura 3.33. Regresión del modelo NARX2 (Serie2).....	64
Figura 3.34. Respuesta de salida del modelo NARX2 (Serie 2).....	65
Figura 3.35. Respuesta de la velocidad de rotación Ngp de la TG durante la demanda de potencia.....	66
Figura 3.36. Respuesta de la temperatura de escape $T5$ de la TG durante la demanda de potencia.....	66
Figura 4.1. Diagrama del sistema de control de la velocidad de rotación de la TG..	69
Figura 4.2. Modelo propuesto por Rowen para una TG de un solo eje y ciclo simple [17].	70
Figura 4.3. Representación del sistema de control del modelo propuesto por Rowen [90].	70
Figura 4.4. Diagrama de bloques del lazo de control de velocidad.	71

Figura 4.5. Diagrama de bloques del lazo de control de la aceleración.	71
Figura 4.6. Diagrama de bloques del lazo de control de temperatura.	72
Figura 4.7. Diagrama de bloques del sistema de control de la velocidad de rotación de la TG.	74
Figura 4.8. Diagrama de bloques basado en el modelo de Rowen de la TG.	75
Figura 4.9. Diagrama en Simulink del modelo y controladores propuestos por Rowen de la TG.	75
Figura 4.10. Valores para la selección del comando del flujo del gas combustible. .	76
Figura 4.11. Respuesta de la temperatura de los gases de escape de la TG.	76
Figura 4.12. Respuesta de la velocidad de rotación de la TG frente a un cambio de consigna.	77
Figura 4.13. Respuesta típica a una señal de prueba estándar del regulador de velocidad propuesto por Rowen.	78
Figura 4.14. Diagrama del controlador MPC basado en una RNA [57].	81
Figura 4.15. Diagrama con los resultados de la identificación de sistema de la TG para el diseño del controlador MPC.	82
Figura 4.16. Datos generados para el entrenamiento del controlador RNA-MPC.	83
Figura 4.17. Datos de entrenamiento del controlador RNA-MPC.	84
Figura 4.18. Datos de validación del controlador RNA-MPC.	84
Figura 4.19. Datos de prueba del controlador RNA-MPC.	85
Figura 4.20. Resultados: (a) entrenamiento, (b) performance alcanzado del controlador RNA-MPC.	85
Figura 4.21. Regresión de la RNA entrenada del controlador RNA-MPC.	86
Figura 4.22. Estructura de la RNA del modelo de la planta del controlador RNA-MPC.	86
Figura 4.23. Diagrama del controlador RNA-MPC con los parámetros ajustados.	87
Figura 4.24. Diagrama del sistema de control en lazo cerrado de la TG con el controlador RNA-MPC.	88
Figura 4.25. Señal de control (FSR) del controlador RNA-MPC.	89
Figura 4.26. Respuesta del sistema de control de la temperatura de salida de la TG con el controlador RNA-MPC.	89
Figura 4.27. Respuesta del sistema de control de la velocidad de rotación de la TG con el controlador RNA-MPC frente a una entrada escalón de la velocidad de 0.05 p.u.	90
Figura 4.28. Diagrama de bloques del controlador NARMA-L2 [43].	92
Figura 4.29. Diagrama de bloques de la identificación de sistema de la TG para el controlador NARMA-L2.	92

Figura 4.30. Datos generados para el entrenamiento del controlador NARMA-L2. .	93
Figura 4.31. Datos de: (a) entrenamiento, (b) validación, (c) prueba del controlador NARMA-L2.	94
Figura 4.32. Resultados: (a) entrenamiento, (b) performance alcanzada con el controlador NARMA-L2.	94
Figura 4.33. Regresión de la RNA entrenada del controlador NARMA-L2.	95
Figura 4.34. Estructura de la RNA del controlador NARMA-L2.	95
Figura 4.35. Diagrama de bloques del sistema de control de lazo cerrado de la TG con el controlador NARMA-L2.	96
Figura 4.36. Señal de control (FSR) del controlador NARMA-L2.	97
Figura 4.37. Respuesta del sistema de control de la temperatura de salida con NARMA-L2.	97
Figura 4.38. Respuesta del sistema de control de la velocidad de rotación de la TG con el controlador NARMA-L2 frente a una entrada escalón de velocidad de 0.05 p.u.	98
Figura 4.39. Bloque del control PID de Simulink-MATLAB.	99
Figura 4.40. Diagrama del sistema de control en lazo cerrado de la TG con el controlador PID.	101
Figura 4.41. Señal de control (FSR) del controlador PID.	101
Figura 4.42. Respuesta del sistema de control de la temperatura de escape de la TG con el controlador PID.	102
Figura 4.43. Respuesta del sistema de control de la velocidad de rotación de la TG con el controlador PID frente a una entrada escalón de velocidad de 0.05 p.u.	102
Figura 4.44. Diagrama de bloques en Simulink-MATLAB del sistema de control de la TG con controladores: Regulador de Velocidad, PID, RNA-MPC y NARMA-L2. ...	104
Figura 4.45. Respuestas de los controladores diseñado frente a una señal de variación aleatoria de la velocidad de rotación de la TG.	105
Figura 4.46. Vista ampliada de las respuestas temporales del sistema de control con los controladores diseñados representadas en la figura 3.48.	105
Figura 4.47. Performances de los controladores: (a) Regulador Velocidad, (b) PID, (c) RNA-MPC, (d) NARMA-L2.	106
Figura 4.48. Señales de control generadas por los controladores diseñados ante una variación en la referencia de velocidad.	107
Figura 4.49. Vista ampliada de las señales de control.	107
Figura 4.50. Respuestas del sistema de control de la temperatura de escape de la TG con los controladores diseñados.	108
Figura 4.51. Vista ampliada de las respuestas presentadas en la Figura 4.50.	108
Figura 5.1. Arquitectura del sistema de control TurboTronic 4. Adaptado de [71]. ...	112

Figura 5.2. Diagrama de bloques del sistema de control de la velocidad de rotación de la TG con controlador basado en RNA..... 113

Figura 5.3. Diagrama de bloques simplificado del sistema de control de la velocidad de rotación de la TG con el controlador NARMA-L2. 113



Índice de Tablas

Tabla 1.1 Clasificación de la TG de ciclo simple.	11
Tabla 1.2 <i>Centrales térmicas conectadas a la red nacional peruana.</i>	14
Tabla 2.1 <i>Efecto del incremento de los parámetros del controlador PID.</i>	26
Tabla 3.1 <i>Especificaciones técnicas de la turbina Centaur 50 para la generación eléctrica.</i>	43
Tabla 3.2 <i>Variables de entrada y salida de la TG objeto de estudio.</i>	44
Tabla 3.3 <i>Conjunto de datos experimentales para la identificación durante el arranque.</i>	49
Tabla 3.4 <i>Valores RMSE del modelo para N_{gp} y $T5$ durante el arranque.</i>	56
Tabla 3.5 <i>Conjunto de datos experimentales para la identificación durante la demanda de potencia.</i>	58
Tabla 3.6 <i>Valores RMSE del modelo para N_{gp} y $T5$ durante la demanda de potencia.</i>	65
Tabla 4.1 <i>Datos de la TG para la generación eléctrica objeto de estudio.</i>	73
Tabla 4.2 <i>Parámetros de caracterización de la TG.</i>	73
Tabla 4.3 <i>Especificaciones de diseño de los controladores.</i>	77
Tabla 4.4. <i>Performance obtenida del sistema de control con el controlador RNA-MPC.</i>	90
Tabla 4.5 <i>Performance obtenida por el controlador NARMA-L2.</i>	98
Tabla 4.6 <i>Ganancias del PID ajustadas para la TG.</i>	100
Tabla 4.7 <i>Performance obtenida del sistema de control con el PID.</i>	103
Tabla 4.8 <i>Características de operación de los controladores diseñados RNA-MPC, NARMA-L2 y PID.</i>	109
Tabla 5.1 <i>Componentes del sistema de control Turbotronic 4.</i>	111

Nomenclatura

Abreviaturas

BNE	balance nacional de energía
CEPLAN	centro nacional de planeamiento estratégico
CIGRE	consejo internacional de grandes sistemas eléctricos
CO	compuestos orgánicos volátiles
CO	monóxido de carbono
COES	comité de operación económica del sistema
DLE	combustión seca de baja emisión
DLN	combustión seca de bajo NOx
FSR	referencia de carrera de combustible
HDGT	turbina de gas de ciclo pesado
HGT	turbina de gas hidrogeno
IEEE	instituto de ingenieros eléctricos y electrónicos
IGV	álabes guía de ingreso
IGV	alabes guía de ingreso de aire
LVS	selector de valor bajo
MAE	error absoluto medio
MPC	Control predictivo basado en modelo
NARMA	media móvil autorregresivo no lineal
NARMA-L2	control por linealización de retroalimentación
NARMAX	media móvil autorregresivo no lineal con entradas exógenas
NARX	autorregresivo no lineal con entradas exógenas
NOx	óxido de nitrógeno
ODS	objetivos de desarrollo sostenible
PID	proporcional integral derivativo
RER	fuentes de energía renovables
RMSE	raíz del error cuadrático medio)
RNA	redes neuronales artificiales
SCR	reducción catalítica selectiva
TG	turbina de gas

Introducción

En la actualidad, el gas natural es considerado a nivel mundial la fuente de energía de transición debido a las grandes reservas existentes y a su industrialización. Además, para el Perú, es el recurso más importante en su matriz energética. En este contexto, las turbinas de gas vienen siendo utilizadas cada vez más, como unidad motriz, tanto para la generación eléctrica (turbo generación) en las centrales de energía, como para el procesamiento y transporte de fluidos (turbo compresión) en diversas plantas industriales. Por consiguiente, resulta de especial interés y de suma importancia los aportes técnicos que se puedan brindar en el campo de la ingeniería del control para mejorar la eficiencia en la operación de estas máquinas.

El modelado y control con alto desempeño de las turbinas de gas constituye un tema de elevada importancia y en constante desarrollo debido a su complejidad dinámica y a la necesidad de lograr una mayor eficiencia. Se reportan diversas investigaciones que buscan profundizar en el estudio de la dinámica de estos dispositivos, para la obtención de modelos matemáticos analíticos y experimentales para su utilización en el diseño de controladores con alto desempeño. No obstante, en la actualidad la operación de las turbinas de gas continúa presentando desafíos, ya que usualmente las mismas se gobiernan mediante controladores convencionales, los cuales no permiten alcanzar el rendimiento deseado. Es por ello, que el desarrollo de controladores avanzados que posibiliten mejorar la respuesta y performance de estas plantas, así como optimizar los recursos energéticos y reducir las emisiones de gases contaminantes, presenta una cimeria actualidad e importancia.

Entre los problemas que exhiben las turbinas de gas se puede mencionar: la pérdida de eficiencia, las emisiones contaminantes, el desgaste y falla prematura de sus componentes, las paradas inesperadas por monitoreo no adecuado, fallos en el sistema instrumentado, y precisión insuficiente de los sistemas de control que no permiten operar con márgenes más eficientes y mayor seguridad. Abordando este último punto es que se ha desarrollado este trabajo de investigación.

La presente tesis tiene el siguiente objetivo general:

- Desarrollar un controlador MPC basado en una RNA que posibilite mejorar el control de la velocidad de rotación de una TG para aumentar su eficiencia.

Para alcanzar este objetivo general se definieron los siguientes objetivos específicos:

- Desarrollar un estudio del estado del arte de la identificación, el modelado y el control de las TG.
- Utilizar métodos de identificación de sistemas basados en algoritmos de aprendizaje automático como son las redes neuronales artificiales y obtener un modelo que caracterice la dinámica de la velocidad de rotación de una TG.
- Diseñar un controlador MPC basado en una RNA para el control de la velocidad de una TG.
- Desarrollar una propuesta de implementación del controlador RNA-MPC diseñado de una TG.

El desarrollo del trabajo de investigación ha sido dividido en capítulos referidos a los objetivos y al avance de las actividades realizadas.

En el Capítulo 1, se presenta el estado de arte de las técnicas para el modelado y el control de las TG mediante la revisión de la literatura especializada disponible en línea, así como en diferentes bases de datos reconocidas en el ámbito científico académico.

En el Capítulo 2, se expone el marco teórico con los conceptos más importantes utilizados en el estudio y que proporcionan la estructura para contextualizar y tratar el problema de control planteado.

En el Capítulo 3, se desarrolla la identificación de una TG industrial para la generación eléctrica a partir del procesamiento de sus datos de operación reales mediante redes neuronales artificiales dinámicas NARX para obtener un modelo de la dinámica de la TG, donde la variable de salida es la velocidad de rotación a partir de la variación del flujo másico del gas combustible.

En el Capítulo 4, se obtiene un modelo matemático simplificado de una TG para una planta de energía fundamentado en el modelo propuesto por Rowen, a partir del cual se diseñan los controladores avanzados basados en redes neuronales artificiales RNA-MPC y NARMA L2, y un controlador clásico PID, donde la variable controlada es la velocidad de rotación de la TG. Se muestran los resultados de los entrenamientos de las RNA y las simulaciones efectuadas sobre los sistemas en lazo cerrado. Se comparan las respuestas obtenidas entre el regulador de velocidad original propuesto por Rowen, los controladores avanzados basados en RNA y el controlador PID clásico.

En el Capítulo 5, se presenta una propuesta de implementación del controlador RNA-MPC desarrollado. Se detallan el hardware y software necesarios para que pueda funcionar en una TG de un solo eje y ciclo simple.

Finalmente, en las conclusiones generales se enuncian las principales inferencias tanto del modelado, así como del diseño y respuesta de los controladores basados en RNA desarrollados. También se hace una descripción de las dificultades encontradas, se brindan recomendaciones para la implementación práctica de un controlador de este tipo en una TG y se proponen futuros temas a desarrollar en este campo de estudio.



Capítulo 1: Estado del arte

1.1 Motivación de la investigación

El sector energético mundial atraviesa un proceso de transición (descarbonización) hacia el uso de las energías renovables (RER). El gas natural, que es un combustible más limpio que otras fuentes como el petróleo, es un actor fundamental para esta transición energética, ayuda a reducir la contaminación ambiental y, por tanto, contribuye a alcanzar los objetivos globales de desarrollo sostenible (ODS) plasmados en la Agenda 2030 de las Naciones Unidas, compromiso asumido por todos los países que la integran. Además, en Perú, la adecuada utilización de este recurso energético aporta al cumplimiento de los objetivos del Plan Estratégico de Desarrollo Nacional al 2050 elaborados por el Centro Nacional de Planeamiento Estratégico (CEPLAN) [1].

Varios trabajos de investigación concluyen que, a pesar de algunos efectos indirectos negativos del gas natural como combustible de transición, no se puede negar sus beneficios directos. La tecnología del gas natural ha atravesado más procesos de evolución comparado con las RER, por ello, este combustible puede soportar a las tecnologías renovables equilibrando su intermitencia, brindando energía confiable, y ofreciendo inversiones y precios asequibles [2]. Sin estos impulsores, la reconfiguración de los sistemas de energía hacia tecnologías renovables puede ser no viable, demasiado cara y tener retrasos.

Se ha demostrado que, en Perú, el gasto de energía depende básicamente del diésel y el gas natural [3]. En el año 2022, de acuerdo con el Balance Nacional de Energía (BNE), las tres fuentes principales de energía fueron: gas natural (incluidos líquidos) con 66%, hidroenergía con 12% y petróleo crudo con 8%. Por tanto, el gas natural aporta de manera significativa en la matriz energética peruana y es un recurso estratégico para nuestra realidad actual [4].

En cuanto, al uso del gas natural en Perú, la mayor parte de este recurso es destinado a la generación eléctrica. Específicamente, para la transformación de fuentes de energía a electricidad, la preponderancia corresponde a las centrales térmicas (56%).

Este grupo está compuesto principalmente por centrales que utilizan gas natural (34%). Las principales tecnologías utilizadas en estas centrales térmicas son: turbinas de vapor, motores de combustión interna, turbinas de gas y ciclos combinados [4].

En este panorama, las TG representan una tecnología importante en la transformación de la energía y en el aprovechamiento del gas natural como recurso estratégico. Además, estas máquinas termodinámicas tienen la capacidad de funcionar con combustibles más limpios y sostenibles como son los biocombustibles y el hidrógeno; por tanto, su desarrollo está en plena vigencia.

La tecnología de turbinas de gas aptas para hidrogeno (HGT), es un enfoque evolutivo e innovador con el potencial de contribuir hacia un panorama de energía más limpia y sustentable, sin embargo, su aplicación se encuentra aún en etapas tempranas de desarrollo y mientras algunos resultados demuestran su viabilidad comercial, persisten retos significativos, como el alto costo de producción del hidrogeno, una combustión no tan eficiente y efectiva, la compatibilidad de materiales y la necesidad de medidas regulatorias de soporte [5].

Es importante indicar que algunos fabricantes ya ofrecen turbinas de gas que funcionan con hidrogeno. Así, GE Vernova ha presentado una solución de turbina de gas aeroderivada 100% preparada para hidrógeno, basada en su paquete LM6000VELOX. Esta se instalará en la central eléctrica Whyalla de 200 MW en Australia Meridional y tiene prevista su puesta en marcha para 2026 [6]. De igual manera, Siemens Energy tiene en su portafolio turbinas de gas con capacidades de combustión a hidrogeno y ha logrado que algunos modelos específicos, como su turbina aeroderivada SGT-A35, puedan trabajar con hasta 100% de hidrogeno como combustible [7].

En base a lo expuesto, los estudios y propuestas que contribuyan a mejorar el funcionamiento de las TG, aumentando su eficiencia y minimizando la emisión de los gases de la combustión, constituyen un tema relevante para la industria energética actual.

1.2 Las Turbinas de Gas

Una TG es una máquina rotativa accionada por la reacción o el impulso de una corriente de un fluido (como agua, vapor o aire) sujeto a presión y generalmente hecho con una serie de alabes curvos montados en un eje giratorio central [8]. También puede ser definida como una maquinaria de fuerza que produce gran cantidad de energía para su tamaño y peso [9].

En general, se puede afirmar, que una TG es una máquina diseñada para convertir la energía térmica de un combustible en algún tipo de potencia útil, como potencia mecánica (del eje) o el empuje de alta velocidad de un reactor. Consta, básicamente, de un generador de gas y una sección de conversión de potencia [10]. El generador de gas consta de las secciones de compresor, cámara de combustión y turbina. En este conjunto, la turbina extrae potencia del eje para impulsar el compresor como en el caso de un turborreactor. Normalmente, en la mayoría de las aplicaciones, la turbina extrae mayor trabajo del eje y el exceso puede ser transmitido a un ventilador conducido (motor de turbofán) o a una hélice (motor de turbohélice). Sin embargo, también puede utilizarse para suministrar trabajo directo al eje o para producir electricidad en una central eléctrica o en una unidad motriz de potencia auxiliar.

Las TG industriales son una tecnología consolidada, disponible en tamaños que van desde 1 MW hasta varios cientos de MW. Producen calor de alta temperatura que puede recuperarse para mejorar su eficiencia energética o utilizarse para generar agua caliente o vapor. El vapor puede generarse a alta presión y luego utilizarse para impulsar una turbina de vapor en una planta de ciclo combinado [11]. Es posible minimizar las emisiones de las TG mediante técnicas como combustión seca, inyección de agua o vapor, o tratamiento de los gases de escape. Los costes de mantenimiento por unidad de potencia son de entre un tercio y la mitad de los que se generan con un motor alternativo. Su bajo mantenimiento y la alta calidad del calor residual suelen convertir a estas turbomáquinas en la opción preferida para muchas aplicaciones de cogeneración comerciales o industriales de gran tamaño. Un papel importante en la cogeneración es la economía de escala, donde las turbinas ofrecen el menor coste de capital por unidad de energía.

1.3 Ciclo Brayton

Los sistemas de las TG operan según el ciclo termodinámico conocido como ciclo Brayton (o ciclo Joule) que describe el funcionamiento de una máquina térmica a presión constante. Se compone de 4 procesos vitales [12]:

1. Compresión isentrópica, donde el aire se comprime adiabáticamente en un compresor, lo que aumenta su presión y temperatura.
2. Adición de calor isobárica, donde el aire a alta presión se calienta a presión constante en una cámara de combustión, lo que aumenta aún más su temperatura.
3. Expansión isentrópica, donde el aire a alta temperatura y presión se expande adiabáticamente a través de una turbina, produciendo trabajo.
4. Rechazo de calor isobárico, que es el proceso en el cual el aire expandido se expulsa a presión constante, completando el ciclo.

Los términos clave asociados con el ciclo Brayton incluyen: proceso adiabático, ya que no se transfiere calor hacia ni desde el fluido de trabajo; proceso isobárico, ya que ocurre a presión constante; y, eficiencia térmica, que define la relación entre el trabajo de salida y el calor de entrada.

En un ciclo Brayton, el aire atmosférico se comprime, se calienta y luego se expande, con el excedente de potencia producida por el expansor (también llamado turbina) sobre la consumida por el compresor, utilizado para la generación de energía.

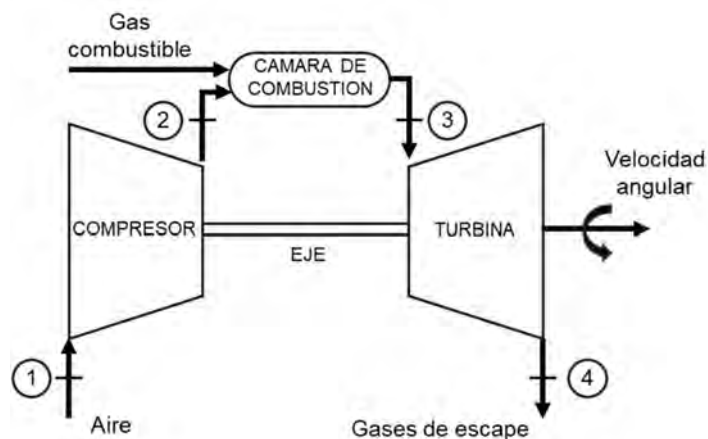


Figura 1.1. Esquema típico de una turbina de gas [13].

En la Figura 1.1 se exhibe el esquema típico de una TG compuesto por un compresor de aire, una cámara de combustión y una turbina. El aire a presión atmosférica entra en el compresor (1), el cual es aumentado por el compresor a su salida (2), y entra en la cámara de combustión para mezclarse con el combustible. Se enciende para producir gases calientes en expansión que ingresan (3) e impulsan la turbina para generar energía mecánica en su eje, el cual gira a una velocidad angular. El trabajo obtenido se utiliza para accionar generadores eléctricos, bombas, compresores. Finalmente, los gases salen de la turbina (4).

El ciclo Brayton, como diagrama de presión-volumen es una representación idealizada de las propiedades de una masa fija de gas (fluido de trabajo) a medida que pasa a través de una TG en funcionamiento. En la Figura 1.2 se puede observar la aplicación simplificada de la primera ley de la termodinámica del Ciclo Brayton de aire en ausencia de cambios de energía potencial y cinética [13].




Figura 1.2 Aplicación de la primera ley de la termodinámica del Ciclo Brayton [13].

La potencia que produce una turbina de expansión y que consume un compresor es proporcional a la temperatura absoluta del gas que pasa a través de ellos. Por consiguiente, en aplicaciones de ciclo simple, resulta conveniente operar la turbina de expansión a la temperatura más alta posible (con materiales compatibles y tecnología de refrigeración interna de los álabes) y operar el compresor con el flujo de aire de entrada a la temperatura más baja posible. A medida que los avances tecnológicos permiten una mayor temperatura de entrada a la turbina, también aumenta la relación

de presiones óptima; sin embargo, en aplicaciones de cogeneración hay otras consideraciones para mejorar la rentabilidad del sistema.

Las relaciones de temperatura y presión más altas resultan en una mayor eficiencia y potencia específica. Por consiguiente, la tendencia en el desarrollo de las TG ha sido hacia una combinación de temperaturas y presiones más altas. Si bien estos avances incrementan el costo de fabricación, el mayor valor, en términos de mayor potencia y eficiencia, puede generar beneficios económicos.

Como aplicaciones del ciclo Brayton, las TG se utilizan ampliamente en centrales eléctricas para generar electricidad. Las centrales eléctricas de ciclo combinado, que integran TG con turbinas de vapor, alcanzan una alta eficiencia aprovechando el calor residual de la TG para producir energía adicional. En aviación, es la base de los motores a reacción, que impulsan la mayoría de las aeronaves modernas. La alta relación empuje-peso y la eficiencia de las TG las hacen ideales para aplicaciones aeronáuticas. También se utilizan en sistemas de propulsión marina, especialmente en buques de guerra y transbordadores de alta velocidad. Su tamaño compacto y su alta potencia las hacen idóneas para este servicio. En cuanto a otras aplicaciones de las TG en el mercado, la industria del petróleo y el gas suele utilizar a las TG para impulsar bombas y compresores, las industrias de proceso las utilizan para impulsar compresores y otros equipos mecánicos de gran tamaño.

En las TG industriales, se logra un equilibrio entre rendimiento y costo que resulta en una máquina más económica tanto para el usuario como para el fabricante. Los gases de escape de las TG son bastante calientes (hasta 590°C en algunas máquinas). Estas altas temperaturas de escape permiten su uso directo. Con la adición de un generador de vapor con recuperación de calor, el calor de escape puede producir vapor o agua caliente. Una parte o todo el vapor generado por la unidad de recuperación de calor (HRSG) puede utilizarse para generar electricidad adicional por medio de una turbina de vapor en una configuración de ciclo combinado.

El futuro del ciclo Brayton reside en su integración con las fuentes de energía renovables y el desarrollo de sistemas híbridos. Se están explorando innovaciones como las TG impulsadas por hidrógeno y las tecnologías de captura de carbono para

que estas sean más sostenibles. Uno de los principales desafíos asociados con el ciclo Brayton es mejorar la eficiencia y reducir las emisiones. Las TG son inherentemente menos eficientes que otros métodos de generación de energía y producen cantidades significativas de emisiones de dióxido de carbono (CO₂) y óxidos de nitrógeno (NO_x).

Las TG, al manejar altas temperaturas y presiones, imponen elevadas exigencias a sus materiales de fabricación para soportar condiciones límite. Estas máquinas requieren un mantenimiento regular para garantizar un funcionamiento confiable y dada su complejidad, el mantenimiento puede ser costoso y requerir un tiempo de indisponibilidad operativa significativo. Para abordar estos desafíos, los investigadores están explorando diversas soluciones, incluyendo: recubrimientos avanzados para proteger los componentes de la turbina de las altas temperaturas y la corrosión; técnicas de enfriamiento mejoradas para gestionar las tensiones térmicas dentro de la turbina; y, sistemas híbridos, que es una combinación de turbinas de gas con otros métodos de generación de energía para mejorar la eficiencia general y reducir las emisiones.

Como corolario, se puede afirmar que el ciclo Brayton es un concepto fundamental en termodinámica e ingeniería, que sustenta el funcionamiento de las TG utilizadas en la producción de energía, la aviación y la propulsión de otras máquinas rotativas. Su desarrollo histórico, aplicaciones prácticas y avances resaltan su importancia en la ingeniería moderna. Si bien persisten desafíos como incrementar su eficiencia, reducir las emisiones y fabricar componentes con menores limitaciones; la investigación y la innovación prometen abordar estos retos y mejorar su rendimiento y sostenibilidad. El ciclo Brayton sigue siendo un área de estudio y desarrollo, con un buen futuro en el panorama de las tecnologías de energía y propulsión [13].

1.4 Las TG para la generación eléctrica

En el campo de la generación de electricidad estas máquinas son instaladas en dos tipos de configuración: ciclo simple y ciclo combinado (cogeneración). Las TG de ciclo simple pueden clasificarse en cinco grupos [9], tal como se exhibe en la Tabla 1.1.

Tabla 1.1
Clasificación de la TG de ciclo simple.

Tipo	Principales aplicaciones	Potencia	Eficiencia
Servicio pesado (HDGT)	Grandes unidades de generación de energía eléctrica.	3 MW a 480 MW	30% - 46%
Aeroderivadas	Unidades de generación eléctrica.	2.5 MW – 50 MW	35% - 45%
Industrial (IGT)	Plantas petroquímicas para manejar trenes de compresión.	2.5 MW – 15 MW	30%
Turbinas pequeñas (SGT)	Unidades de generación de energía y fuentes de respaldo eléctrico.	0.5 MW – 2.5 MW	15% - 25 %
Microturbinas (MGT)	Unidades de generación distribuida.	20kW – 350 kW	15% - 30%

Nota. Adaptado de [9].

Los componentes principales de una TG para la generación eléctrica son: el generador de gas, compuesto por el compresor y la turbina de potencia, la cámara de combustión, y el generador eléctrico. Estos componentes se exhiben en la Figura 1.3.

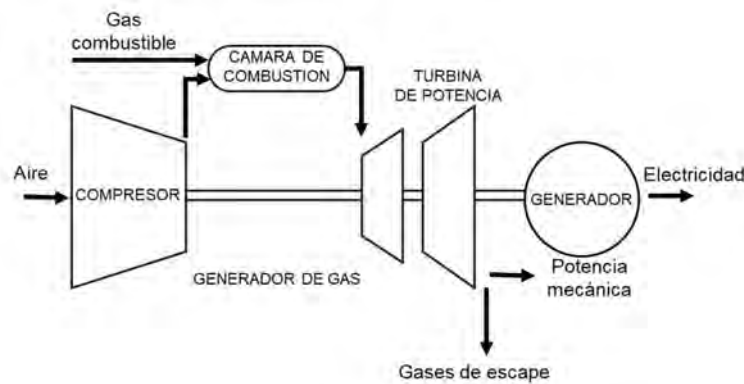


Figura 1.3. Principales componentes de una TG [13].

La tecnología más eficiente para la generación de energía en centrales eléctricas es la planta de ciclo combinado de una TG y una turbina de vapor, con eficiencias cercanas al 60%. El esquema típico de estos sistemas se muestra en la Figura 1.4. Existen TG de ciclo simple para la generación exclusivamente eléctrica con eficiencias cercanas al 40%. Las TG se han utilizado durante mucho tiempo en las compañías eléctricas para cubrir la demanda máxima. Sin embargo, con los cambios en la industria eléctrica y los avances tecnológicos, las TG se utilizan cada vez más para la

generación de energía de carga base. Las TG producen calor de escape de alta calidad que puede utilizarse en configuraciones de cogeneración para alcanzar eficiencias generales del sistema (electricidad y energía térmica útil) del 70 al 80%.

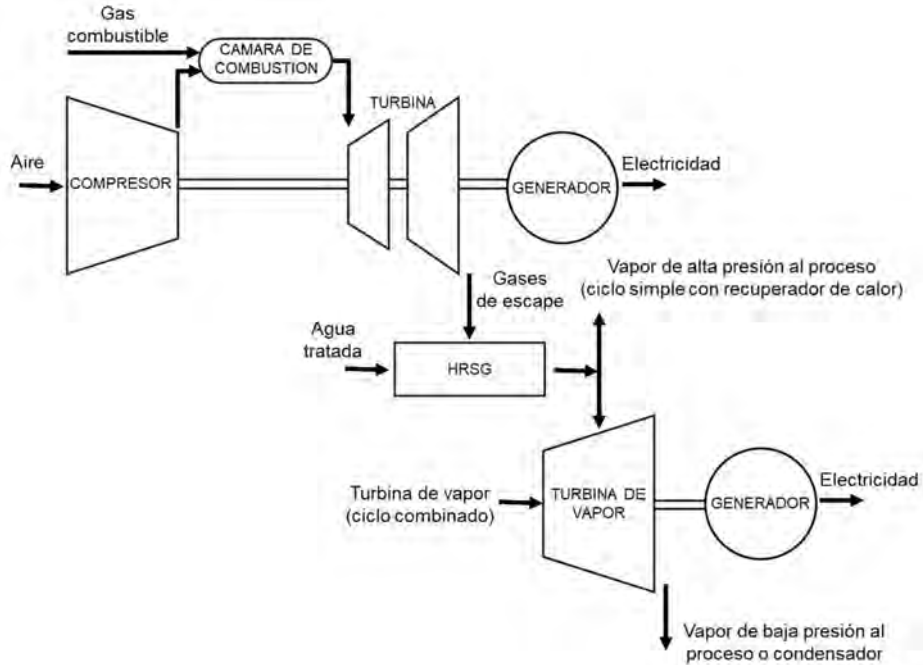


Figura 1.4. Esquema de un sistema de cogeneración basado en una turbina de gas [13].

Los principales contaminantes de las TG son el NO_x, el monóxido de carbono (CO), y los compuestos orgánicos volátiles (COV). La carga operativa tiene un efecto significativo en las emisiones de estos contaminantes. Ya que las TG operan con cargas elevadas, su diseño busca la máxima eficiencia y condiciones óptimas de combustión a altas cargas. Controlar los contaminantes simultáneamente en todas las condiciones de carga resulta difícil. A cargas más altas, se producen mayores emisiones de NO_x debido a las temperaturas pico de la llama. A cargas más bajas, se produce una menor eficiencia térmica y una combustión incompleta, lo que resulta en mayores emisiones de CO y COV. Las mejoras en el control de NO_x y en la combustión de las TG se centraron en reducir las temperaturas de los puntos calientes de la llama mediante mezclas pobres de aire y combustible, y una combustión premezclada (DLN / DLE). Estas tecnologías buscan disminuir la relación aire/combustible en las zonas donde se produce NO_x, de modo que la temperatura máxima de la llama sea inferior a su temperatura adiabática estequiométrica,

suprimiendo así la formación de NOx. En las cámaras de combustión donde se utilizan estas técnicas, se requieren diseños específicos para cada aplicación. Un problema reconocido son las llamas piloto o de difusión necesarias para mantener la ignición interna continua, siendo fuentes de NOx. Otro problema, es el ruido, ya que se forman ondas acústicas debido a la inestabilidad de la combustión al encenderse el combustible premezclado y el aire. Estas ondas de presión pueden dañar las paredes de la cámara de combustión y disminuir su vida útil, incrementando los costos de mantenimiento y reduciendo la disponibilidad de la unidad [11]. Los fabricantes líderes de TG que incorporan esta tecnología garantizan emisiones de NOx de hasta 15 ppm, sin embargo, es un desarrollo costoso debido a las dificultades para mantener un funcionamiento confiable de las turbinas de gas en un amplio rango de potencia.

El principal método de control de NOx postcombustión es la reducción catalítica selectiva (SCR), que consiste en inyectar amoníaco en los gases de combustión para producir N₂ y H₂O. Esta tecnología puede reducir hasta un 90 % las emisiones de NOx. En combinación con la combustión DLN, la SCR puede generar niveles NOx de hasta 2 ppm. Pero, se trata de sistemas costosos y de alto riesgo, ya que requieren almacenamiento de amoníaco en el sitio [11].

La energía térmica de los gases de escape representa hasta el 70% de la energía del combustible de ingreso, por lo que su uso eficaz mejora la rentabilidad de las TG. Así, los gases de escape pueden utilizarse para procesos de calentamiento y secado de manera directa o mediante un intercambiador.

Actualmente, muchas empresas industriales utilizan TG para generar electricidad para su uso local. Cuando se utilizan para generar energía en la misma instalación, las TG suelen emplearse en cogeneración, donde la energía de los gases de escape de la turbina proporciona energía térmica a la planta. Las instalaciones industriales de gran tamaño instalan TG de ciclo simple para proporcionar energía durante las horas punta en zonas con capacidad limitada, y las compañías eléctricas suelen colocar TG de entre 5 MW y 40 MW en subestaciones para aumentar la capacidad y respaldar la red [11].

1.5 Las TG en Perú

En Perú, la mayoría de las TG utilizadas para generación de electricidad están instaladas en las centrales térmicas. Se trata de sistemas de generación con TG en configuración de ciclo combinado.

A diciembre 2024, las cinco centrales que entregan mayor potencia al Sistema Interconectado Nacional (COES, 2025) y que utilizan turbinas de gas en sus instalaciones se exhiben en la Tabla 1.2.

Tabla 1.2
Centrales térmicas conectadas a la red nacional peruana.

Nombre	Operador	Salida (MW)	Fuente
Central Termoeléctrica Kallpa	Kallpa Generación S.A.	908	Gas
Central Termoeléctrica Chilca Uno	Engie Energía Perú S.A.	862	Gas
Central Termoeléctrica Puerto Bravo	Samay I	616	Diesel Gas
Planta Termoeléctrica Fenix Power	Fenix Power Perú S.A.	570	Gas
Central Térmica Ciclo Combinado Ventanilla	Enel Generación Perú S.A.A.	485	Gas

Nota. Se muestran las centrales térmicas conectadas a la red peruana que entregan mayor potencia de acuerdo con el BNE 2022 [4].

1.6 Identificación, modelado y control de una TG

Por tratarse de máquinas imprescindibles para la industria energética y que desempeñan un rol clave como motor primario diversos sectores, se han llevado a cabo numerosas investigaciones a nivel mundial para el modelado y control de las TG. Sin embargo, debido a su estructura y al retardo en su proceso de combustión interna es necesario desarrollar una matemática complicada basada en leyes físicas para su modelado. Esto ha motivado a los investigadores a explorar nuevos métodos para predecir el comportamiento dinámico de estos sistemas no lineales lo más preciso posible, ya que, para el control y el monitoreo de su operación, se requiere un modelo que represente con adecuada aproximación a su comportamiento real.

Se puede mencionar que los principales objetivos para el modelado de una TG incluyen [13]:

- Simuladores para propósitos de entrenamiento.
- Monitoreo de condiciones y diagnóstico de fallos.
- Actualización de la performance del sistema de control.
- Estudios de estabilidad (señales de estabilidad grandes y pequeñas).

Para captar las tendencias de modelado de las TG encontradas en la literatura, el estudio sobre el modelado puede clasificarse como sigue:

1. Modelos físicos, basados en leyes físicas y parámetros de identificación por conjuntos de datos.
2. Modelos empíricos con estructura predefinida, la cual está basada en conjuntos de datos operacionales.
3. Modelos matemáticos simplificados, los cuales son principalmente funciones de transferencia derivadas de sistemas físicos e identificados para adaptarse a la respuesta de la planta.

Los modelos de caja blanca de una TG describen su comportamiento usando ecuaciones físicas basadas en principios de ingeniería. Estos modelos son utilizados cuando hay suficiente conocimiento acerca de la física del sistema y pueden ser modelos no lineales o linealizados [14, 15].

Tal como afirma Bielski [15], los modelos teóricos son la forma convencional de modelar el comportamiento de las TG, por ejemplo, el modelo de Rowen [16,17] el modelo IEEE [18] o el modelo CIGRE [19]. Estos están basados en ecuaciones específicas para cada aplicación y capturan con precisión el comportamiento temporal de las TG al modelar la interacción entre los diversos componentes del sistema y las condiciones operativas. Este proceso depende de la obtención de mediciones de los componentes internos del sistema mediante sensores físicos; sin embargo, implica un importante esfuerzo de parametrización. Como alternativa a estos modelos basado en la teoría, algunos investigadores han recurrido a modelos de aprendizaje profundo basados en datos y de amplia aplicación para predecir directamente la potencia de salida de las turbinas de gas a partir de datos operativos. Si bien este enfoque ha demostrado ser prometedor para reducir los esfuerzos de parametrización, estudios previos que evaluaron estos métodos se centraron en escenarios donde las mediciones de los componentes internos del sistema eran accesibles [20]. Sin embargo, esto no siempre se garantiza debido al esfuerzo necesario y los costos asociados.

Los modelos de caja negra tienen como objetivo modelar el comportamiento de una TG para un conjunto de datos de entrada y salida cuando poco o ningún dato está disponible sobre la información del sistema físico. Uno de los más importantes métodos en este tipo de modelado es la red neuronal artificial (RNA), que ha demostrado alta precisión en aplicaciones industriales y permite la optimización del consumo de combustible de una TG.

A pesar de que el uso de las RNA para aplicaciones industriales puede ser controversial, su capacidad para capturar la dinámica de sistemas sin un conocimiento previo sobre ellos y sus ecuaciones dinámicas complicadas es una ventaja importante [21]. El uso de RNA proporciona nuevos enfoques y soluciones novedosas para el modelado, la simulación y el control de una TG.

En estudios como el desarrollado por Asgari y Chen [22, 23, 24, 25], se describen criterios importantes a considerar al comienzo del proceso de modelado, como son: tipos y configuraciones de TG, tipos y configuraciones de sistemas de control, y, métodos y objetivos de modelado. Se investigan los campos de modelado de caja

blanca y caja negra, simulación y control de las TG, donde se exploran modelos para TG de baja potencia y TG de plantas de energía industrial (IPGT). Se examinan las estructuras de las RNA y el proceso de construcción de modelos basados en RNA, incluido el análisis del sistema, la adquisición y preparación de datos, la arquitectura de la red y el entrenamiento y validación. Se presenta una notable metodología basada en RNA para la identificación de sistemas fuera de línea de TG y se complementa con modelos validados que utilizan datos operativos simulados y reales. Se cubre el modelado del comportamiento transitorio y el arranque, así como el diseño de controladores basados en RNA.

En el trabajo publicado por Mohamed y Khalil [13], se revisan las técnicas de modelado y los controladores aplicadas a las centrales eléctricas con TG. Se discuten filosofías de modelado recientes y se muestran las estrategias de control viables más avanzadas. Se presenta un estudio exhaustivo que abarca los intentos para modernizar las técnicas, con énfasis en diferentes aspectos y características de las turbinas. La revisión crítica de las diversas metodologías publicadas resulta muy útil para demostrar la importancia de esta área de investigación en términos prácticos y técnicos. Se clasifican los diferentes enfoques de modelado y se investiga cada categoría individualmente mediante la revisión de un número considerable de artículos de investigación. Se presentan las principales características de cada categoría o enfoque. También, se revisan las estrategias modernas de control multivariable para las TG y se proponen tendencias futuras y recomendaciones para investigación.

En cuanto a estudios orientados solo al control de TG, se tienen trabajos de investigación como el desarrollado por Singh, Maity y Nataraj [26], donde se propone un control avanzado de velocidad del eje de una TG basado en un control de realimentación de Lyapunov cuyos resultados muestran una mejor performance en puntos intermedios de operación. Si bien el diseño propuesto no tiene gran robustez, el control de realimentación presenta ventajas, por lo que puede ser tomado como una prueba de concepto.

El estudio de Zhang et al. [27] considera los altos requisitos de control para la regulación de la velocidad del eje que se presenta en el ámbito de flexibilidad

operativa de las TG. Se indica que los modelos de control predictivo proporcionan una metodología para su operación segura y eficiente. Sin embargo, al trabajar a carga parcial, el controlador se degrada debido a la discrepancia entre el modelo predictivo y la dinámica de la TG. Para abordar el problema de la adaptabilidad del modelo, se propone un controlador MPC en compensación. La dinámica de la planta es modificada por el observador de estado extendido para acercarse al integrador puro. El control predictivo se diseña con base en la planta modificada. La regulación de carga de amplio rango y el rechazo de perturbaciones de la TG se han mejorado al aprovechar las ventajas del control MPC basado en la compensación.

Las TG son sistemas complejos cuyo funcionamiento a máximo rendimiento presenta desafíos. En los trabajos de Hadroug et al. [28, 29] se propone el uso de un enfoque híbrido basado en un sistema de inferencia neuro difusa adaptativa (ANFIS) para el control de la velocidad y la temperatura de escape de una TG. El objetivo principal es mantener el funcionamiento de la turbina a un rendimiento óptimo. Los resultados obtenidos, basados en el uso del modelo de Rowen, demuestran la eficacia del enfoque híbrido de control de velocidad y temperatura de escape propuesto.

Para Cao et al. [30], las TG presentan un papel importante tanto en la generación de energía como en la regulación de frecuencia de la red eléctrica. En su artículo, diseñan un sistema de control de velocidad para TG de alta potencia. Específicamente, el control de velocidad se organiza en cuatro fases: convertidor de frecuencia de arranque, controlador de rampa de aceleración, controlador de velocidad/carga y un control dependiente de la red. En primer lugar, el convertidor determina la velocidad durante el arranque inicial. En segundo lugar, tras la parada del convertidor, el controlador de rampa de aceleración asume el control de velocidad hasta alcanzar la velocidad nominal. Posteriormente, se selecciona el controlador de velocidad/carga mediante un selector de mínimo para controlar la velocidad de la TG. Finalmente, tras la sincronización con la red eléctrica, la velocidad de la turbina de gas depende de la frecuencia de la red. Para estudiar las características dinámicas del sistema de control de velocidad, se diseñó un modelo de la turbina de gas con su sistema de control en SIMULINK, basado en el método de modelado modular. Los resultados de la simulación mostraron un buen rendimiento de las respuestas

transitorias por lo que el sistema de control de velocidad diseñado podría regular la TG durante una condición variable.

Najimi y Hossein [31] desarrollaron un diseño de un controlador robusto H_∞ para un modelo de una TG de la central eléctrica Montazer Ghaem (GE9001E). En la fase de diseño, se aplicó un modelo lineal (modelo ARX) obtenido a partir de datos reales. Dado que la turbina se utiliza en una central eléctrica de ciclo combinado, su velocidad y la temperatura de los gases de escape deben ajustarse simultáneamente controlando las señales de combustible y la posición de los álabes guía de entrada del compresor (IGV). Considerando las limitaciones de las entradas del sistema, el objetivo del control es mantener la velocidad de la TG y la temperatura de los gases de escape dentro del intervalo deseado bajo incertidumbres y perturbaciones de la demanda de carga. Los resultados de la simulación con el controlador robusto propuesto en el modelo no lineal del sistema (modelo NARX) cumplieron los objetivos predefinidos. Las simulaciones también mostraron una mejora en el desempeño en comparación con los controladores MPC y PID para las mismas condiciones.

Lee y So [32] publicaron un estudio, donde se presenta una técnica de modelado para un generador de gas, un actuador con servo motor lineal (PLA) y una válvula dosificadora de gas combustible, pertenecientes a una TG. Obtuvieron submodelos en varios puntos de operación en estado estacionario basados en los datos de prueba y proponen un método para controlar la velocidad del motor mediante el diseño de un controlador PID no lineal (NPID) para cada submodelo. El controlador NPID propuesto utiliza tres tipos de ganancias implementadas con una función no lineal. Los parámetros del controlador NPID se ajustan mediante algoritmos genéticos de código real para minimizar la función objetivo. La validez del método propuesto se examina aplicándolo a una TG y realizando una simulación.

En la publicación de Mansourabad, Beheshti y Simab [33] se diseña un controlador híbrido PSO_Fuzzy_PID para el control de velocidad de una TG. Su objetivo es mantener la velocidad de la TG y la temperatura de escape en un intervalo deseado durante el arranque y la condición de operación. Se presentan diferentes partes del controlador difuso como la fuzzificación, la base de reglas, el motor de inferencia, la defuzzificación y el algoritmo de optimización de enjambre de partículas (PSO). Se

realizan simulaciones del controlador y la TG en Matlab/Simulink para investigar la efectividad del algoritmo propuesto. El rendimiento fue evaluado durante el arranque y la condición de operación. Los resultados muestran que la respuesta del controlador PSO_Fuzzy_PID mejora efectivamente en comparación con otros controladores. Las características de la respuesta al escalón como el tiempo de subida, el tiempo de asentamiento y el sobre impulso se reducen considerablemente, y el valor del error de estado estacionario se minimiza.

También, se tiene un reciente estudio desarrollado por Hashmi, Mansouri y Assadi [34], donde se presenta una descripción general del estado del arte, los métodos y tecnologías de la performance dinámica y las estrategias de control para turbinas de baja potencia o microturbinas de gas (MGT). Algunos de los mayores resultados encontrados en este estudio son:

- Prevalen los estudios numéricos y pocos investigadores han considerado el estudio de performance experimental para evaluar el rendimiento transitorio.
- Los regímenes transitorios de arranque y paro son por lo general responsables de varias fallos y paros de emergencia, incluidas las sobrecargas en el compresor y daños en cojinetes debido al calor excesivo.
- Los enfoques de modelado basado en la dinámica física se basan en el volumen concentrado para la inercia del fluido; sin embargo, la inercia térmica ha sido tomada en cuenta por pocos estudios.
- La mayoría de los estudios dinámicos han implementado controladores convencionales PI y PID. Sin embargo, los controladores avanzados basados en inteligencia artificial, como controladores difusos PID (FPID) ofrecen una estabilidad robusta y mejor performance durante arranques y paros.

Otros estudios, como el de Saadat et al [35], proponen la implementación de un controlador inteligente para una TG, basado en lógica difusa (Fuzzy Logic). Para lograr este enfoque se utilizó un modelo de simulación capaz de describir la dinámica de la TG para asegurar una respuesta óptima del sistema bajo estudio.

Un estudio bastante completo es el presentado por Mohamed y Khalil [13] donde se revisa el progreso en el modelado y las técnicas de control para las TG de sistemas

de generación eléctrica. Destacan en su trabajo la claridad con que se han clasificado los diversos trabajos analizados. Especial atención tiene el modelado enfocado en inteligencia artificial (IA) y aprendizaje de máquina (ML). En cuanto a las estrategias de control avanzado, se reconoce al control MPC, como la tecnología más popular y la que actualmente provee resultados más factibles [36]. Esta estrategia constituye en el enfoque fundamental del control con alto desempeño de las plantas de energía debido a que por su naturaleza maneja bien las restricciones de operación práctica y la aplicación de la optimización matemática de las señales futuras [37, 38].

También en relación con los métodos de control de una TG para la generación de energía, en Guo et al. [39] se publicó una investigación, para mejorar el rendimiento del controlador original, donde proponen un nuevo método de control integrado que combina este controlador con un nuevo controlador de red neuronal. Este método controla la velocidad alternando ambos controladores durante el funcionamiento de la máquina. Realizaron pruebas de seguimiento y robustez para evaluar el nuevo método y los resultados muestran que, en comparación con el controlador original y el nuevo controlador de red neuronal, el nuevo método de control integrado presenta un rendimiento de seguimiento de velocidad mucho mejor. Además, observaron que cuando el modelo de la TG varía con la temperatura ambiente y la degradación del rendimiento del compresor, la robustez del nuevo método de control integrado también es mejor que la de los otros dos controladores.

1.7 Modelo de Rowen para turbinas de gas

En la literatura se ha encontrado que uno de los primeros modelos, el cual también es uno de los más difundidos, aceptados y utilizados para simular el comportamiento dinámico de una TG es el modelo introducido y completado por Rowen [17, 18], el cual es una representación matemática simplificada de una TG HDGT. Este modelo asume las siguientes premisas [40, 41]: se trata de una TG de alto rendimiento que opera en un ciclo simple sin recuperación de calor; se mantiene una velocidad relativamente constante entre el 95 % y el 107 % de la velocidad nominal, y, opera a una temperatura ambiente de 15°C y a una presión ambiente de 101,325 kPa.

Las funciones de transferencia de su modelo consideran: la limitación de la demanda de combustible, el consumo en vacío (sin carga), el modelado del posicionador de la válvula, la dinámica del sistema del gas combustible, los retardos de descarga de volumen, los modelos de par de salida y de temperatura, el sistema de medición de temperatura; y, el sistema de álabes guía de entrada al compresor axial o IGV.

Los IGV regulan el flujo másico de aire aspirado por el compresor. Su función es mantener la temperatura de salida a un valor constante, es decir, el punto de diseño, para alcanzar el máximo rendimiento de la TG. En la Figura 1.5 se presenta un diagrama de bloques del sistema de control de una TG con los controladores principales: el controlador de carga/velocidad, también conocido como controlador de carga/frecuencia, el controlador de aceleración, el controlador de temperatura, y el controlador de los álabes guía de ingreso de aire IGV.

Los parámetros del modelo de Rowen para una TG pueden calcularse utilizando datos operacionales. Tavakoli, Vahidi y Gawlik [41] propusieron un conjunto de ecuaciones para extraer estos parámetros. Estas ecuaciones se basan en reglas termodinámicas. Cabe mencionar que el objetivo es calcular los parámetros del modelo en condiciones de plena carga y si bien estos parámetros calculados aún son utilizables en condiciones de carga y descarga, es necesario considerar el efecto de la posición del IGV en el modelo.

1.8 Conclusiones

Las investigaciones sobre el modelado y control de las TG aplicadas a centrales eléctricas han generado avances notables en su operación y eficiencia, por lo que el estudio del estado del arte, así como el seguimiento de los logros y tendencias recientes en este campo son esenciales para el desarrollo de nuevos y efectivos sistemas de control de las TG y de futuras investigaciones en este importante campo del conocimiento.

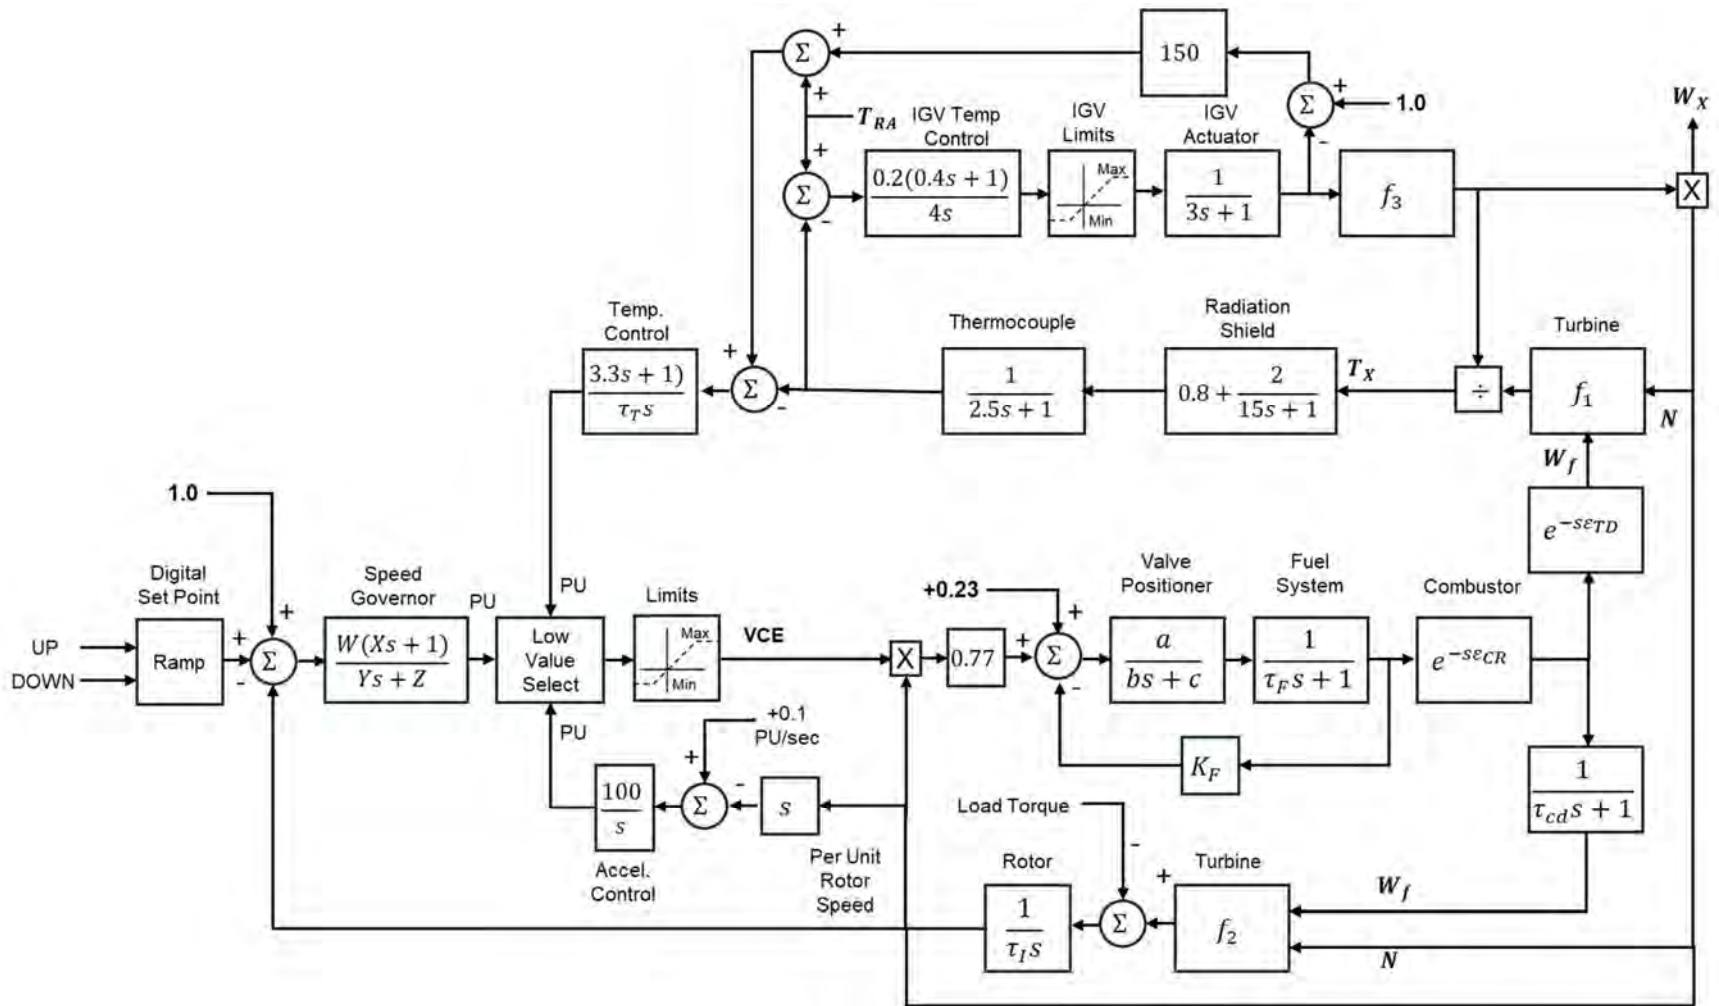


Figura 1.5. Representación matemática simplificada del sistema de control de una TG para estudios dinámicos [17, 18].

Capítulo 2: Marco Teórico

Introducción

En la actualidad, es imprescindible disponer de controladores confiables para comandar las operaciones de los diversos procesos industriales de manera óptima y con las restricciones de diseño y seguridad [42, 43]. Estos controladores deben ser capaces de gestionar las restricciones en las estrategias de control y las variables internas [44]. Esta necesidad ha impulsado el desarrollo de varios tipos de controladores para que puedan desempeñarse con éxito en múltiples aplicaciones [45]. Además, debido a la naturaleza no lineal de los procesos y a la desviación de los sistemas de control respecto de los objetivos de diseño, aún existe una demanda de controladores avanzados y enfoques de control que incorporen la no linealidad y la adaptabilidad [45]. En este contexto, las RNA tienen una gran capacidad para modelar y controlar sistemas dinámicos complejos como las turbinas de gas.

2.1 Controlador PID

El controlador proporcional-integral-derivativo (PID) se utiliza en la industria desde 1939 y es el controlador más aplicado en los sistemas de control automático hasta la actualidad [46]. Se puede definir como un controlador genérico que actúa en función de la diferencia entre los valores de una variable de proceso medida y una señal de referencia [90, 91]. El objetivo del controlador es minimizar esta diferencia o error, mediante el ajuste de las señales de control de los diferentes procesos [22].

El controlador PID incluye los parámetros: proporcional (P), integral (I) y derivativo (D), que pueden interpretarse en términos del tiempo. P, I y D dependen, respectivamente, del error actual, de la acumulación de errores pasados, y de la predicción de errores futuros [46]. La sintonización del controlador constituye el proceso de ajuste o de obtención de estos parámetros para lograr el desempeño deseado [92]. El comportamiento óptimo frente a un cambio en el proceso o un cambio del punto de operación varía dependiendo de la aplicación [47]. La popularidad de los

controladores PID se debe a su flexibilidad ya que presentan diferentes opciones de diseño en función de la dinámica del proceso.

El algoritmo del controlador PID es el siguiente [94, 95]:

$$u(t) = K(e(t) + \frac{1}{T_i} \int_0^t e(\tau) d(\tau) + T_d \frac{de(t)}{dt}) \quad (2.1)$$

donde $u(t)$ representa la señal de control, $e(t)$ es el error, K es la ganancia proporcional, T_i es el tiempo integral y T_d es el tiempo derivativo. Por lo tanto, la señal de control está compuesta por la suma de tres parámetros: P , I y D [48].

Este controlador puede ser representado mediante una estructura paralela como se exhibe en el diagrama de bloques de la Figura 2.1.

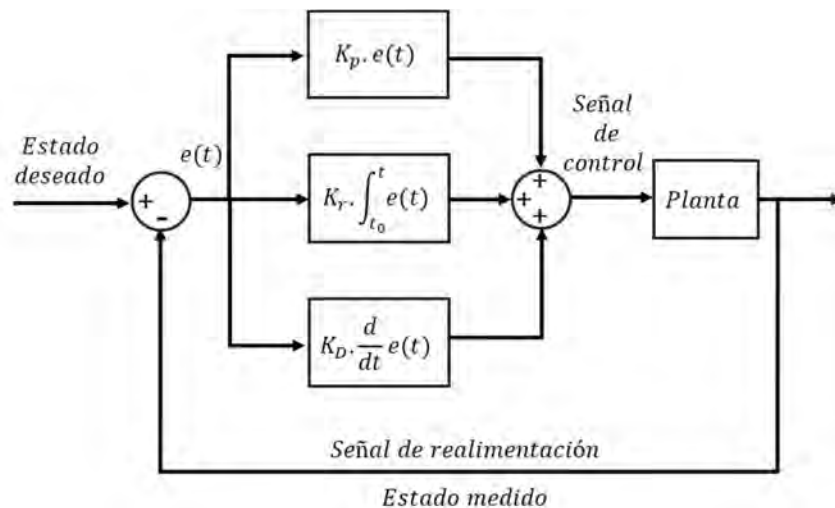


Figura 2.1. Diagrama de bloques del sistema de control con estructura paralela del PID [47].

A diferencia de otros controladores, el PID puede ajustar las salidas de los procesos mediante la historia y tasa de cambio de la señal de error, lo cual brinda una mayor precisión y estabilidad. Además, los controladores PID no requieren matemática avanzada y algoritmos de control óptimo [48, 49, 50, 51].

Las principales características de la respuesta temporal en lazo cerrado son: el tiempo de subida, el sobre impulso, el tiempo de establecimiento y el error de estado

estacionario. Los efectos del incremento de los parámetros del controlador PID se muestran en la Tabla 2.1:

Tabla 2.1
Efecto del incremento de los parámetros del controlador PID.

Parámetro	Tiempo de subida	Sobre impulso	Tiempo de establecimiento	Error de estado estable
K_P	Decrementa	Incrementa	Cambio pequeño	Decrementa
K_I	Decrementa	Incrementa	Incrementa	Elimina
K_D	Cambio pequeño	Decrementa	Decrementa	Cambio pequeño

Nota. Tomado de [47].

En el presente trabajo, se utilizó Simulink-MATLAB para la implementación del controlador PID. Además, para su sintonía se empleó su herramienta de sintonización PID Tuner, la cual se ajustó manualmente según los criterios de diseño hasta obtener la respuesta deseada.

2.2 Las redes neuronales artificiales (RNA)

La RNA se ha convertido en un componente fundamental del campo de la inteligencia artificial. Surgida en 1943 de la investigación de McCulloch y Walter Pitts [52], se puede describir como un modelo informático fundamentado en la estructura y funciones de las redes neuronales biológicas. Una RNA se modifica o aprende según su entrada y su salida. La información que se difunde a lo largo de la red altera su estructura [53].

Como características principales de las RNA se pueden mencionar: tienen tres capas interconectadas, la primera está compuesta por neuronas de entrada que transmiten datos a la segunda capa, que a su vez envía datos de salida a la tercera capa. Las RNA son herramientas de modelado estadístico de datos no lineales que se utilizan para simular interacciones complejas entre entradas y salidas, para descubrir patrones o tendencias, y, son un tipo de tecnología de aprendizaje profundo que se enmarca en la categoría de inteligencia artificial. En la Figura 2.2 se presenta un diagrama de la arquitectura de una RNA [54].




Figura 2.2. Arquitectura de una RNA [54].

Gracias a su notable capacidad para extraer significado de los datos, una RNA entrenada puede considerarse una experta en la categoría de información para la que ha sido preparada y utilizarse para generar proyecciones ante nuevas situaciones de interés y responder a preguntas hipotéticas [55].

Otras ventajas de las RNA incluyen:

- Aprendizaje adaptativo: La capacidad de aprender a realizar tareas basándose en los datos para el entrenamiento o la experiencia previa.
- Autoorganización: Una RNA puede organizar o representar por sí misma la información que obtiene durante el tiempo de aprendizaje.
- Operación en tiempo real: Los cálculos de una RNA pueden realizarse en paralelo, y se están creando y construyendo componentes de hardware específicos que aprovechan esta característica.
- Tolerancia a fallos: Mediante la codificación de información redundante, una avería parcial de la red puede reducir el rendimiento o incluso si la red sufre daños graves, ciertas funciones de la red pueden conservarse.

2.2.1 El modelo NARX

El modelo NARX es un tipo de RNA con retroalimentación, adecuado para sistemas de modelado no lineal, especialmente series temporales, que utilizan mediciones pasadas para predecir valores futuros [56]. Se basa en el modelo lineal auto regresivo con entrada exógena ARX, comúnmente utilizado en el modelado de series temporales. El modelo NARX se define como [98]:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-ny), u(t-1), u(t-2), \dots, u(t-nu)) \quad (2.2)$$

donde el valor de la señal de salida dependiente $y(t)$ es una regresión de los valores previos de las señales de salida $y(t)$, y de la entrada independiente (exógena) $u(t)$. El modelo NARX se puede implementar utilizando una RNA de propagación hacia adelante para aproximar la función f .

En la Figura 2.3 se exhibe una estructura general de la red NARX, con una red de propagación hacia adelante de dos capas para la aproximación, donde *TDL* (*tapped delay line*) es el retardo de tiempo; *IW* (*input weights*) y *LW* (*layer weights*) son los pesos de las entradas y de la capa oculta que determinan la fuerza de conexión entre los nodos; y , b son los parámetros *bias* en las capas ocultas. Esta implementación también permite un modelo ARX vectorial [57].

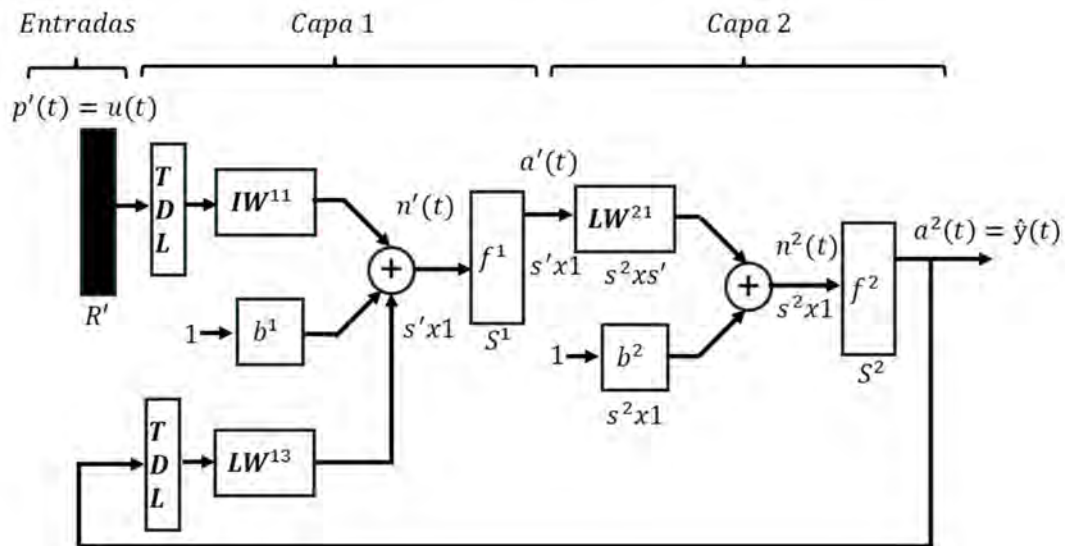


Figura 2.3. Estructura de la red NARX [57].

Las conexiones de retroalimentación de este tipo de redes les permiten retener el conocimiento de intervalos de tiempo anteriores, a diferencia de las RNA de retroalimentación estándar, que procesan los datos de entrada estrictamente hacia adelante, sin retroalimentación. Las redes NARX se caracterizan porque al ser redes "no lineales" capturan conexiones dentro de los datos simulando dinámicas y patrones

complejos que podrían no estar conectados linealmente. El término "autorregresivo" describe la capacidad de la red para pronosticar valores futuros utilizando pronósticos pasados como entradas e integrando conexiones de retroalimentación. Además, las redes NARX integran variables o factores externos que podrían afectar la variable objetivo bajo predicción (entradas exógenas); de esta forma permiten que la red tenga en cuenta datos externos e internos, lo que mejora la predicción.

La estructura de la red NARX tiene una capa de entrada, que recibe los datos iniciales, (series temporales y variables exógenas); capas ocultas, que aprenden patrones de los datos procesándolos mediante sumas ponderadas; funciones de activación; conexiones de retroalimentación, para capturar interdependencias reteniendo la información de intervalos de tiempo anteriores; y, una capa de salida, que genera valores pronosticados utilizando relaciones aprendidas y datos de entrada. Con este diseño, se combinan patrones autorregresivos y factores externos para pronosticar con precisión datos de series temporales [99].

Como ventajas de las redes NARX se tiene: su capacidad para representar conexiones no lineales complejas en los datos; su capacidad de recordar y utilizar datos de intervalos de tiempo anteriores, lo cual es esencial para la predicción de series temporales; su capacidad para mejorar la precisión de la predicción, incorporando datos de variables externas; su versatilidad adecuada para una amplia gama de actividades, incluyendo el modelado dinámico de sistemas, el procesamiento de secuencias y la predicción de series temporales; su adaptabilidad ya que puede ajustarse a tendencias cambiantes y aumentar constantemente el rendimiento previsto con datos adicionales; su robustez al ruido eliminando eficazmente la información superflua; y, su eficacia de aprendizaje eficaz ya que se pueden utilizar algoritmos estándar para un entrenamiento eficiente, lo que permite una rápida implementación en diversas aplicaciones.

2.3 Controlador predictivo basado en redes neuronales artificiales (RNA-MPC)

El "controlador MPC se ha convertido en la técnica estándar para el control en diversas industrias de procesos, con aplicaciones en plantas de refinación,

petroquímica, química, pulpa y papel, y procesamiento de alimentos. Esta estrategia de control se desarrolló a finales de la década de 1970 y se generalizó, en la década de 1980 [96, 97].

Entre los factores que han contribuido al uso generalizado del MPC en las industrias de procesos [58], se tiene:

- El control multivariable, debido a que los procesos industriales usualmente son sistemas acoplados de múltiples entradas y múltiples salidas (MIMO). El control MIMO puede implementarse mediante MPC.
- Las restricciones en las entradas y salidas de los procesos debido a consideraciones de seguridad son comunes en las industrias de procesos. Estas restricciones pueden integrarse en el cómputo de la señal de control mediante MPC.
- Las herramientas que facilitan el desarrollo de modelos y la implementación de controladores han permitido el aumento del control MPC en las industrias de procesos.

El control MPC se basa en la resolución de un problema de optimización para las acciones de control en cada intervalo de muestreo. Mediante este, un optimizador calcula futuras acciones de control que minimizan la diferencia entre la salida de un modelo del proceso y el rendimiento deseado en un horizonte temporal (normalmente, el horizonte temporal es mayor que el tiempo de estabilización del proceso en lazo abierto).

Además de minimizar una función objetivo, el optimizador se utiliza para observar un conjunto de restricciones. Es común establecer límites superiores e inferiores para las entradas, así como límites para la tasa de cambio de la entrada. Luego de calcular la trayectoria de las futuras acciones de control, solo el primer valor de la trayectoria se envía como punto de ajuste a los actuadores. El cálculo del control óptimo se vuelve a ejecutar en cada intervalo de muestreo utilizando un modelo actualizado mediante retroalimentación. La forma del modelo, la función objetivo, las restricciones y el tipo de optimizador han sido áreas de investigación activas durante las últimas décadas. Varios trabajos de investigación sobre MPC abordan estos temas [58, 59, 60, 61].

El controlador RNA-MPC implementado en la herramienta Deep Learning Toolbox de MATLAB, hace uso de un modelo de red neuronal de una planta no lineal para predecir su comportamiento. El controlador determina la señal de control para optimizar el rendimiento de la planta en un periodo futuro. Es decir, el primer paso es establecer el modelo de la red neuronal de la planta (identificación del sistema), para que luego, el controlador utilice este modelo para anticipar la respuesta futura de la planta.

La primera etapa del RNA-MPC consiste en entrenar la RNA para describir la dinámica de la planta. Como señal de entrenamiento para la RNA, se utiliza la diferencia entre la salida de la planta y la salida de la RNA (o el error de predicción), tal como se detalla en el diagrama de bloques de la Figura 2.4.

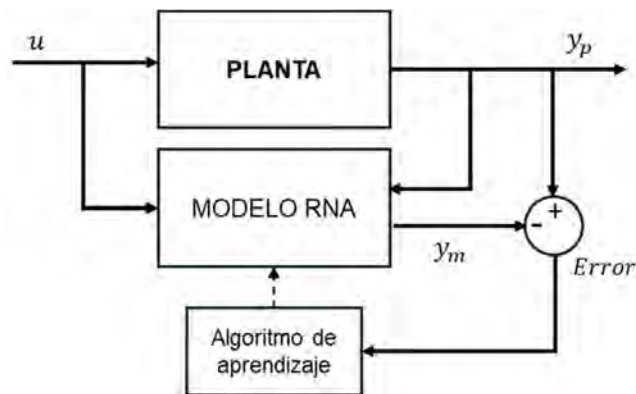


Figura 2.4. Proceso de entrenamiento del controlador MPC [57].

El modelo de la RNA de la planta toma en cuenta las entradas y salidas previas para predecir los valores futuros de su salida. La estructura del modelo basado en una RNA de la planta se muestra en la Figura 2.5.

Esta RNA es posible entrenarla en modo offline por lotes, utilizando datos recopilados durante la operación de la planta. Se pueden utilizar diferentes algoritmos de entrenamiento de la RNA como la función *trainlm*, la cual reajusta los valores de peso y sesgo (*bias*) según la optimización de *Levenberg-Marquardt*.

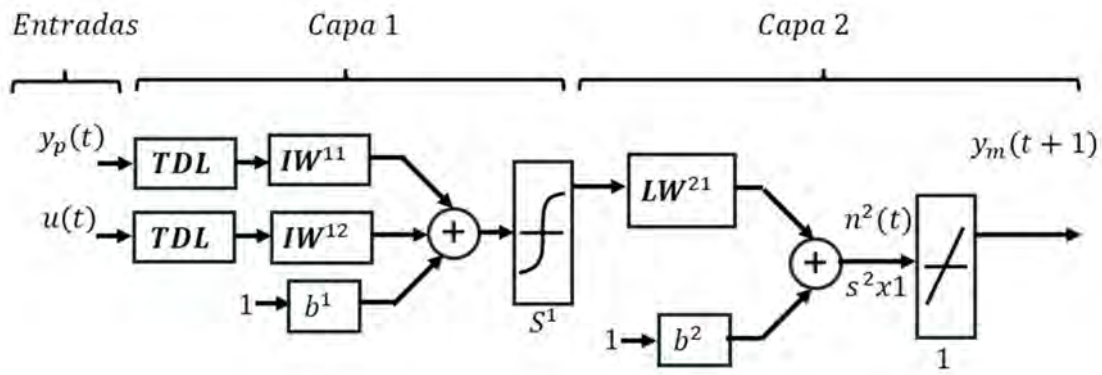


Figura 2.5. Estructura del modelo basado en una RNA [57].

El control MPC se fundamenta en la técnica de horizonte de retroceso [62]. El modelo basado en una RNA predice la respuesta de la planta durante un horizonte temporal específico. El optimizador utiliza las predicciones para determinar la señal de control que minimiza el siguiente criterio de desempeño durante el horizonte especificado:

$$J = \sum_{j=N_1}^{N_2} (y_r(t+j) - y_m(t+j))^2 + \rho \sum_{j=1}^{N_u} (u'(t+j-1) - u'(t+j-2))^2 \quad (2.3)$$

donde N_1 , N_2 y N_u son los horizontes en los que se evalúan el error de seguimiento y los incrementos de control, u' es la señal de control tentativa, y_r es la respuesta deseada, e y_m es la respuesta de la RNA. El término ρ determina la contribución de la suma de los cuadrados de los incrementos de control al índice de rendimiento. En la Figura 2.6 se ilustra un sistema de control predictivo basado en una RNA.

El controlador consta del modelo de la planta basado en una RNA y del bloque de optimización. El bloque de optimización determina los valores de u' que minimizan J , y luego se introduce el u óptimo en la planta.

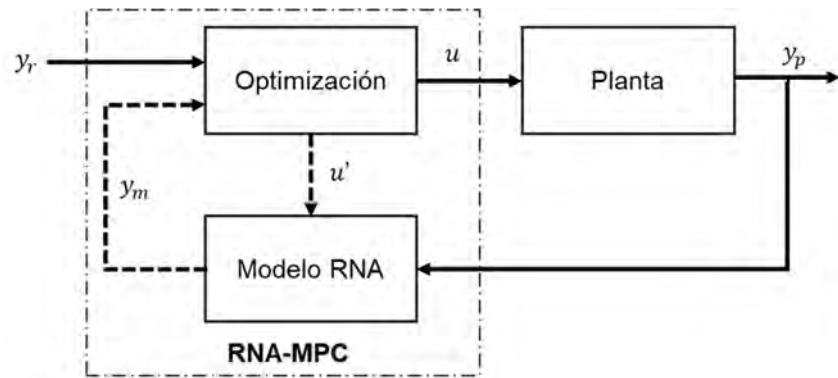


Figura 2.6. Arquitectura del sistema de control basado en una RNA con un controlador MPC.

2.4 Controlador de linealización por retroalimentación (NARMA-L2)

Este controlador neuronal se conoce con dos nombres: controlador de linealización por retroalimentación y controlador de media móvil autorregresivo no lineal (NARMA-L2). Cuando el modelo de la planta presenta una forma complementaria, se denomina controlador de linealización por retroalimentación y cuando puede aproximarse mediante la misma forma se denomina controlador NARMA-L2.

El concepto fundamental de este tipo de control es transformar sistemas dinámicos no lineales en sistemas dinámicos lineales cancelando las no linealidades [57]. Cabe indicar que esta cancelación solo se puede asegurar en el modelo teórico, no en una implementación física real.

Se trata de un modelo estándar utilizado para describir sistemas no lineales generales de tiempo discreto. Es decir, este modelo representa el comportamiento de entradas-salidas de sistemas dinámicos no lineales de dimensión finita de tiempo discreto en una vecindad del estado de equilibrio.

De la misma forma que con el control MPC, la primera etapa para usar el control de linealización por retroalimentación (NARMA-L2) es la identificación del sistema que se va a controlar. Se entrena una RNA para representar la dinámica directa del sistema. La estructura del modelo que se utiliza como referencia para representar el sistema no lineal en tiempo discreto es el modelo de media móvil autorregresivo no lineal (NARMA):

$$y(k+d) = N[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-n+1)] \quad (2.4)$$

donde $u(k)$ es la entrada del sistema, e $y(k)$ es la salida del sistema.

Durante la etapa de identificación, es posible entrenar una RNA para aproximar la función no lineal N . Este es el procedimiento de identificación utilizado por el controlador MPC basado en una RNA. Ya que se pretende que la salida del sistema acompañe la trayectoria de referencia $y(k+d) = y_r(k+d)$, lo siguiente es desarrollar un controlador no lineal de la manera:

$$u(k) = G[y(k), y(k-1), \dots, y(k-n+1), y_r(k), u(k-1), \dots, u(k-m+1)] \quad (2.5)$$

El problema con este controlador radica en que, si se desea entrenar una RNA para crear la función G y minimizar el error cuadrático medio, se requiere retro propagación dinámica [63, 64]. Esto puede requerir bastante tiempo. Una solución, propuesta por Narendra y Mukhopadhyay [65], consiste en utilizar modelos aproximados para representar el sistema. El controlador utilizado por la herramienta Deep Learning Toolbox se basa en el modelo aproximado NARMA-L2:

$$\begin{aligned} \hat{y}(k+d) = & f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m+1)] \\ & + g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-m \\ & + 1)].u(k) \end{aligned} \quad (2.6)$$

Este modelo está en forma complementaria, donde la siguiente entrada del controlador $u(k)$ no está contenida dentro de la no linealidad. La ventaja de esta forma es que se puede calcular la entrada del controlador que hace que la salida del sistema siga la referencia $y(k+d) = y_r(k+d)$. El controlador resultante tiene la forma:

$$u(k) = \frac{y_r(k+d) - f[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)]}{g[y(k), y(k-1), \dots, y(k-n+1), u(k-1), \dots, u(k-n+1)]} \quad (2.7)$$

Aplicar esta ecuación de forma directa puede causar problemas de implementación, ya que se debe resolver la entrada de control $u(k)$ en función de la salida $y(k)$ al mismo tiempo. Por lo tanto, el modelo resultante (para $d \geq 2$) es:

$$y(k+d) = f[y(k), y(k-1), \dots, y(k-n+1), u(k), u(k-1), \dots, u(k-m+1)] + g[y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)].u(k+1) \quad (2.8)$$

La Figura 2.7 presenta la estructura general de la RNA NARMA-L2.

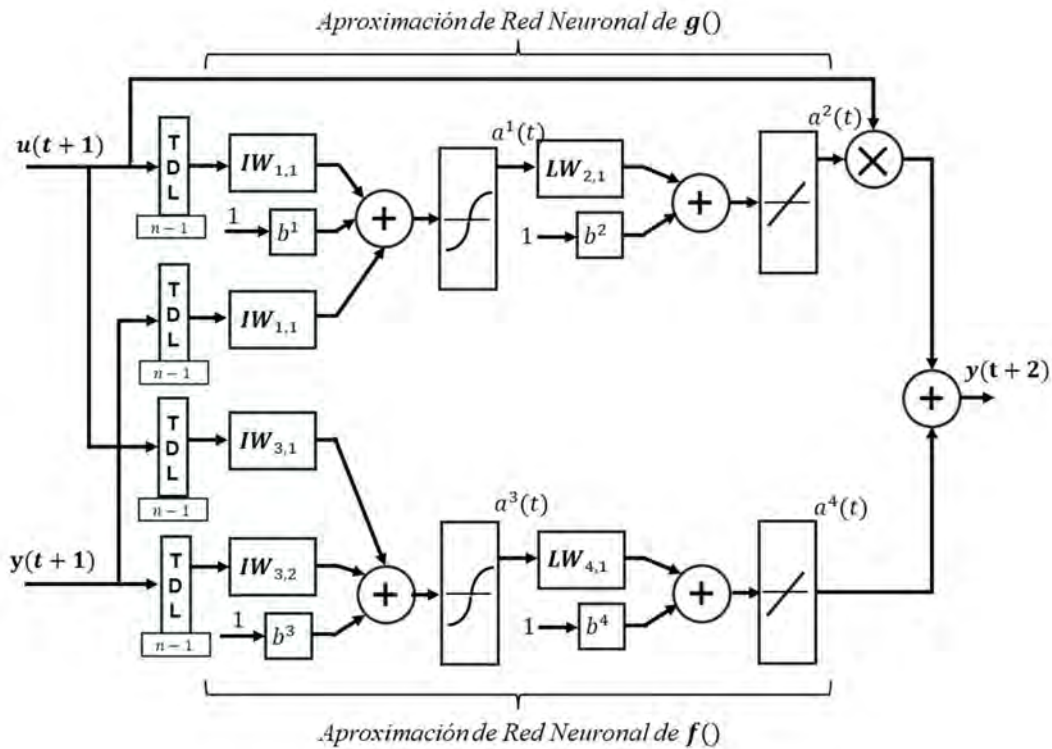


Figura 2.7. Estructura de la RNA NARMA-L2 [57].

Utilizando el modelo NARMA-L2, es posible obtener un controlador realizable para $d \geq 2$, de la forma:

$$u(k+1) = \frac{y_r(k+d) - f[y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)]}{g[y(k), \dots, y(k-n+1), u(k), \dots, u(k-n+1)]} \quad (2.9)$$

El diagrama de bloques de este controlador se muestra en la Figura 2.8.

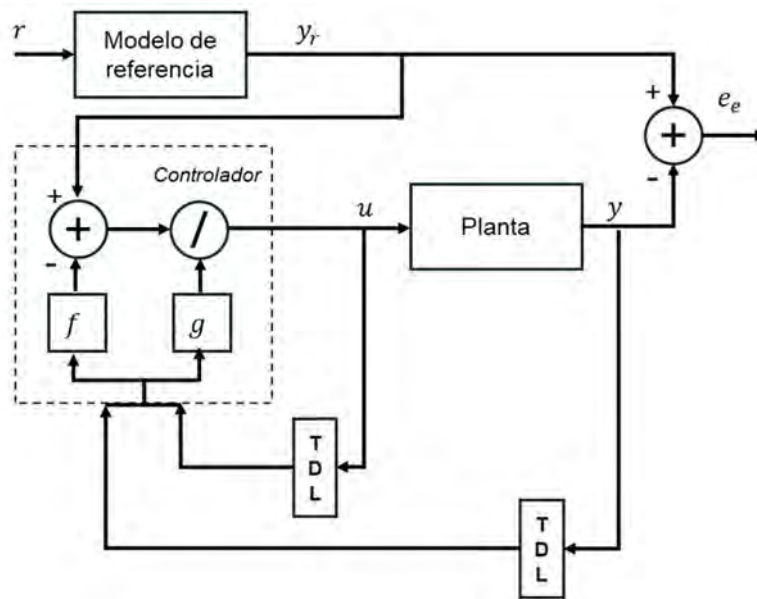


Figura 2.8. Diagrama de bloques del controlador NARMA-L2 [57].

Este controlador se puede implementar, considerando el modelo de la planta previamente identificada, tal como se muestra en la Figura 2.9.

En esta representación se observa el diagrama de bloques del controlador NARMA-L2, que consta de 2 RNA multicapa, denominadas f y g , y de 2 líneas de retardo presentes en la estructura utilizadas para almacenar valores anteriores de las señales de entrada y salida.

El controlador utiliza primero una entrada aleatoria que ingresa a la planta y almacena la salida correspondiente, luego, determina la relación entre la entrada y la salida mediante una estructura lineal compuesta por ponderaciones y minimiza la ecuación de ponderaciones de manera iterativa hasta alcanzar la ponderación óptima que mejor describe la correlación entre la entrada y la salida. Utilizando esta ponderación, el controlador se prueba con nuevos valores de entrada [66].

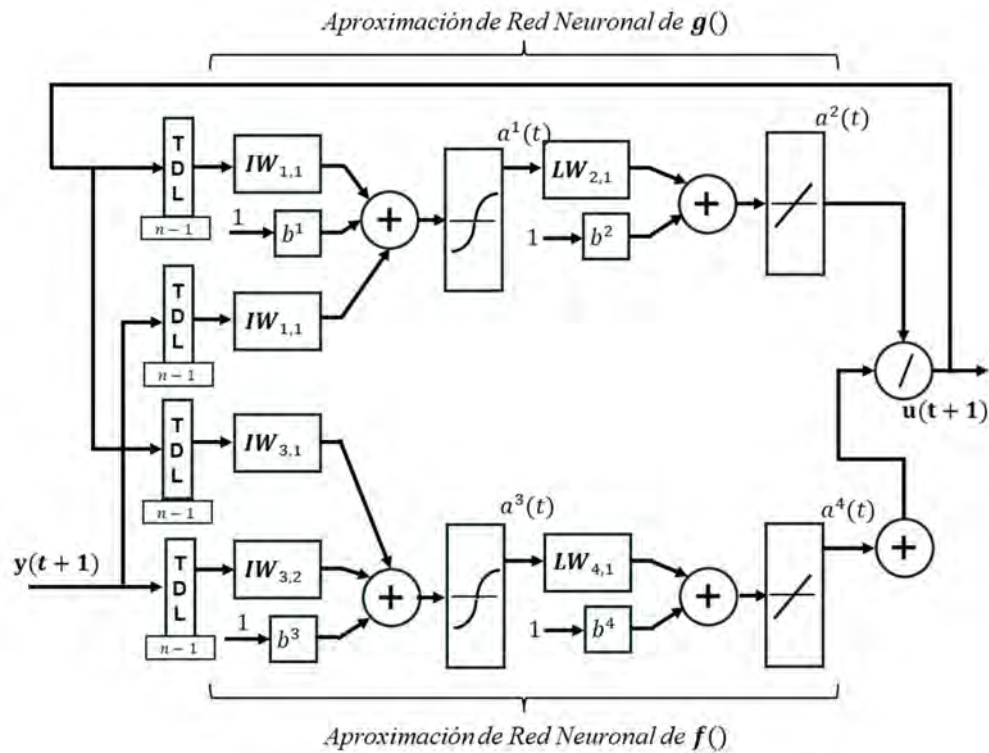


Figura 2.9. Estructura del controlador neuronal NARMA-L2 [57].

2.5 Conclusiones

Se planteó el marco teórico que se aplicará en el desarrollo de esta tesis. Se presentaron: los fundamentos del controlador clásico proporcional-integral-derivativo (PID), los fundamentos de las RNA y su aplicación en el control avanzado mediante el controlador MPC basado en RNA (RNA-MPC), y el controlador de linealización por retroalimentación (NARMA-L2).

Capítulo 3: Identificación basada en RNA de una TG

Introducción

Se desarrolla el proceso de identificación del comportamiento dinámico de una TG utilizado para la generación eléctrica. Se aborda el tema desde el enfoque de modelado de sistemas industriales categorizado como caja negra. El modelado representa una etapa imprescindible en el diseño de controladores avanzados [51, 67].

El objetivo consiste en encontrar las relaciones entre las variables del sistema utilizando los datos operativos de entrada y salida obtenidos durante el funcionamiento de la máquina en las etapas de arranque y demanda de carga. Para lograrlo se ha considerado utilizar las RNA, ya que son uno de los métodos que más destacan en esta función; además, han tenido un rápido crecimiento y se han experimentado en diferentes plantas industriales en los últimos años. La idea principal de las RNA consiste en proporcionar un modelo simple que representa al cerebro humano para resolver problemas complejos.

3.1 Las TG como objeto de control automático

Si bien es cierto, que la literatura revisada evidencia una gran cantidad de actividades de investigación en el área del modelado, simulación y control de las turbinas de gas, aún se necesita resolver problemas relativos a sus procesos de diseño, construcción, operación y mantenimiento. Algunos de estos problemas en los modelos y sistemas de control existentes se destacan en [21].

Las metodologías de modelado y control basadas en ecuaciones termodinámicas y de balance energético tienen un alto grado de no linealidad. Es inevitable considerar supuestos y utilizar métodos de linealización para simplificar y resolver estas dinámicas complejas. Por tanto, los modelos y sistemas de control basados en estas ecuaciones no son lo suficientemente precisos para capturar la dinámica, lo que conduce a problemas como paradas repentinas. Se requiere utilizar técnicas y

metodologías independientes de la dinámica. Además, los controladores convencionales difícilmente pueden manejar procesos altamente no lineales y variables en el tiempo [68, 69, 70].

Los componentes de las TG se deterioran gradualmente y pierden su operatividad y eficiencia con el tiempo, en consecuencia, los modelos de caja blanca para estas máquinas están sujetos a cambios y dejan de ser válidos. Así, predecir el comportamiento de las TG antiguas es muy difícil. Además, los modelos de caja negra son muy útiles en este caso debido a su independencia y adaptabilidad a nuevas condiciones [79]. El entrenamiento y uso de un modelo actualizado basado en RNA, a partir de nuevos conjuntos de datos de la TG, pueden resolver el problema.

Los modelos de las TG, disponibles en la literatura, consideran principalmente el funcionamiento en estado estacionario de las turbinas, por lo que se requiere profundizar en los procesos transitorios y de arranque. Existe demanda de mejoras en los modelos y sistemas de control de las TG que sean estables ante cambios en las condiciones ambientales y perturbaciones derivadas de fallos o fluctuaciones de carga en la red eléctrica. Para el modelado y control basados en RNA, existen diversos enfoques y metodologías en investigación.

Así, para el proceso de identificación de la TG objeto estudio, se ha considerado el modelo de una RNA autorregresiva no lineal con entradas exógenas (NARX) propuesto en [22, 23, 24, 25]. Para su diseño se utilizará el método sistemático para este tipo de red formulado en [14].

3.2 Método para el modelado

Para lograr la identificación y obtener un modelo basado en una RNA NARX para la TG bajo estudio se consideró el método sistemático propuesto en [14], el cual se exhibe en la Figura 3.1.

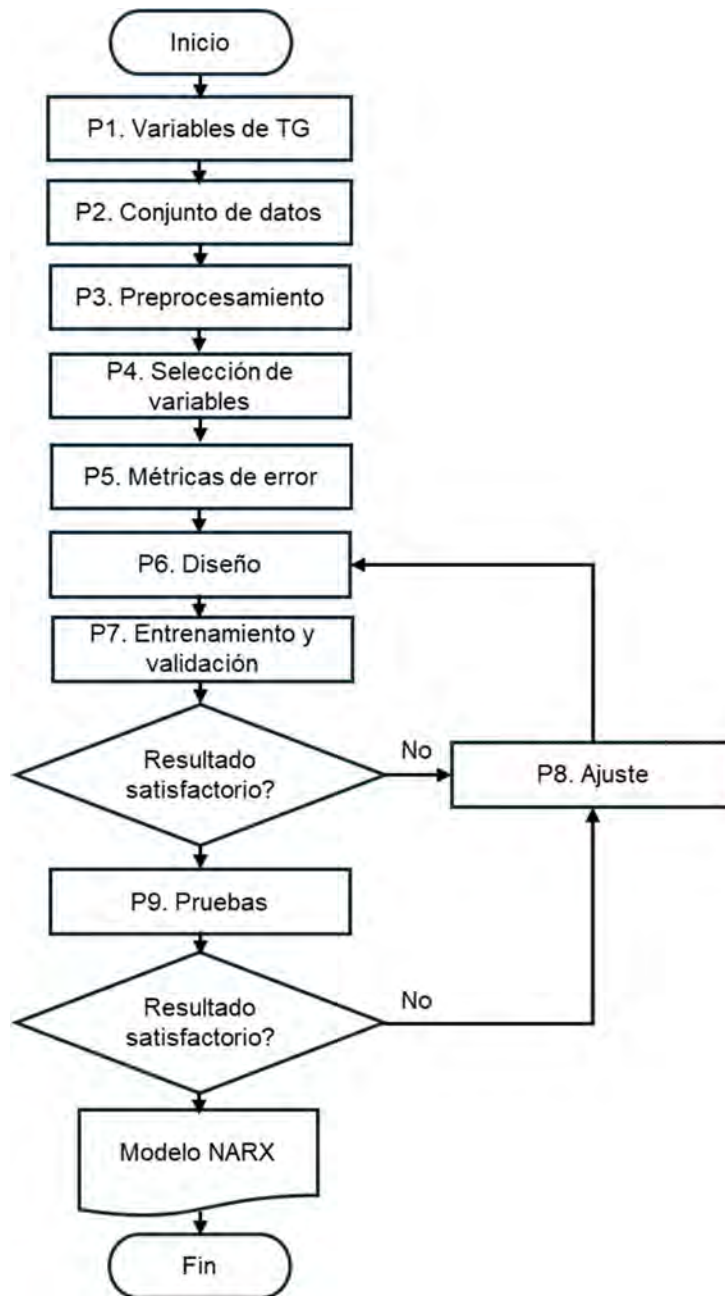


Figura 3.1. Método para el diseño sistemático de un modelo NARX [14].

3.3 Variables fundamentales del proceso

La TG objeto de estudio, para demostrar la validez de la identificación mediante RNA, es una turbina de un solo eje y ciclo simple, que forma parte de un turbogenerador marca Solar, modelo Centaur 50 y que es utilizada para la generación de electricidad en una empresa privada de procesamiento de gas natural. Un diagrama de este

turbogenerador se muestra en la Figura 3.2. Este turbogenerador es un paquete integrado y operacional que cuenta con todos los accesorios y sistemas auxiliares necesarios para su operación. Ha sido diseñado para el servicio industrial, es compacta, ligera y requiere un mínimo espacio para su instalación [71].




Figura 3.2. Esquema del turbogenerador Centaur 50 típico [71].

Consiste en una TG de flujo axial, un generador eléctrico y una caja reductora. Estos componentes están instalados en un patín de acero pesado. La parte de la turbina es integral y autónoma. Combina operación de alta performance con una construcción industrial robusta. En la Figura 3.3 se pueden ver las partes principales de la turbina.

En cuanto a su funcionamiento, esta realiza un proceso de combustión típico (Figura 3.4), el aire ingresa y es comprimido por el compresor de flujo axial multietapas, luego es direccionado dentro de la cámara de combustión anular a un flujo estable. El combustible es inyectado y mezclado con el aire comprimido y encendido durante el ciclo de arranque. La combustión se mantiene mientras haya un adecuado flujo de aire y combustible. El gas caliente presurizado desde el combustor se expande a través de la turbina, disminuyendo su presión y temperatura hasta que sale de esta. El ciclo de combustión convierte la energía del combustible en potencia rotativa cinética aplicada en el eje de la turbina. Para la combustión, la TG requiere aproximadamente de una cuarta parte del aire total que comprime. El aire en exceso es mezclado con los productos de combustión para reducir la temperatura del gas en la primera etapa de ingreso de la turbina. El aire de enfriamiento mantiene la temperatura de los metales del conjunto relativamente bajos para asegurar la vida útil de los materiales.




Figura 3.3. Partes principales de la turbina Centaur 50 [71].

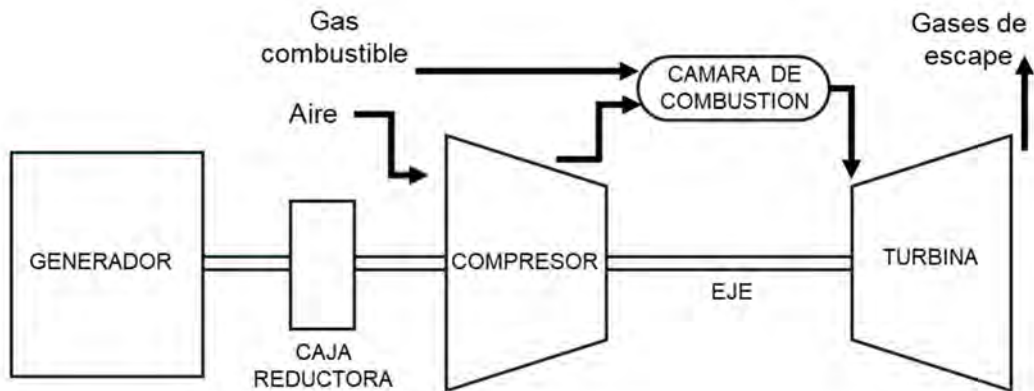


Figura 3.4. Proceso de combustión típico [71].

Las especificaciones de diseño del turbogenerador se presentan en la Tabla 3.1.

Tabla 3.1
Especificaciones técnicas de la turbina Centaur 50 para la generación eléctrica.

Compresor	
Tipo	Flujo axial
Número de etapas	11
Relación de compresión	10.6
Flujo (nominal)	18.8 kg/s (41.4 lb/s)
Cámara de combustión	
Tipo	Anular
Ignición	Antorcha
Numero de inyectores	12
Turbina de Potencia	
Tipo	Reacción
Número de etapas	3
Velocidad (nominal)	14944 rpm (50 Hz) 14951 rpm (60 Hz)
Performance	
Salida de potencia	4600 KW (6522 hp)
Relación calorífica	12268 kJ/kW-hr (11,628 Btu/kW-hr)
Flujo de escape	68,680 kg/hr (151,410 lb/hr)
Temperatura de escape	510 °C (950 °F)
Caja de cambios	
Tipo	Reductora
Velocidad de salida	1500 rpm (50 Hz) 1800 rpm (60 Hz)

Nota. Adaptado de [71]. El rendimiento del gas combustible se calcula bajo las siguientes condiciones: Rating nominal ISO a 15 °C (59 °F), nivel del mar, sin pérdidas de aire al ingreso o en el escape, humedad relativa al 60%, poder calorífico inferior (LHV) de 31.5 a 43.3 MJ/nm³ (800 a 1100 Btu/scf).

En el presente trabajo de investigación, los datos para el análisis fueron obtenidos de los transmisores instalados en la unidad para el monitoreo de sus variables de operación, por medio de la herramienta de registro de datos del sistema de control del propio fabricante, denominado Turbotronic 4, incluido en el equipamiento del turbogenerador. La arquitectura de este sistema está basada en la plataforma de Rockwell Automation / Allen Bradley e incluye una integración completa con la turbina,

el generador, el monitor de vibraciones y el monitor del subsistema de detección de gas y fuego. La ubicación de las variables de la TG se presenta en la Figura 3.5.

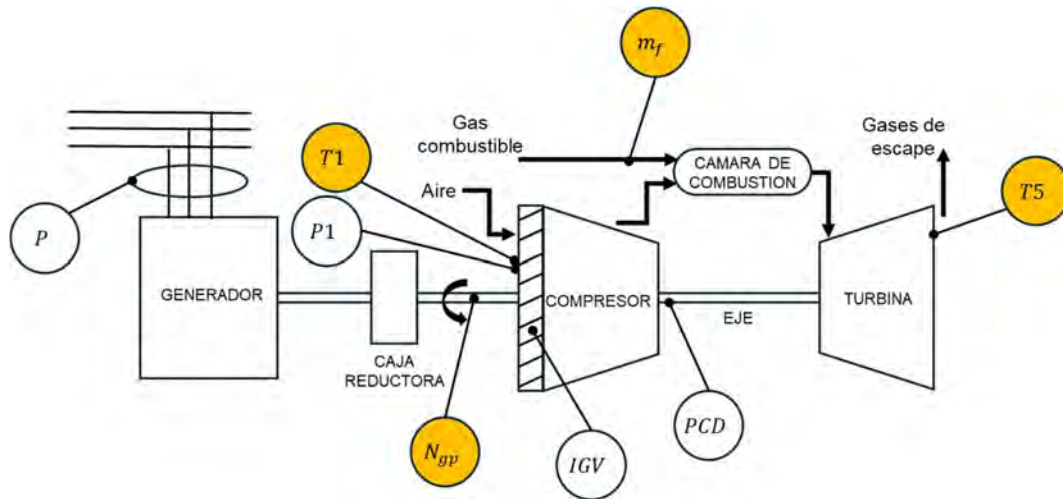


Figura 3.5. Ubicación de las variables de la TG.

Las variables de entrada y salida de la turbina obtenidas en la etapa de adquisición de datos se presentan en la Tabla 3.2.

Tabla 3.2
Variables de entrada y salida de la TG objeto de estudio.

Variables de entrada	Variables de salida
Flujo másico del gas combustible m_f (lb/h)	Velocidad de rotación N_{gp} (%)
Temperatura de ingreso $T1$ (°F)	Temperatura de los gases de escape $T5$ (°F)
Presión de ingreso $P1$ (psig)	Potencia entregada al sistema P (kW)
Presión de descarga del compresor PCD (psig)	
Posición de álabes guía de ingreso al compresor IGV (%)	
Posición de la válvula principal del gas combustible (%)	
Posición de la válvula piloto del gas combustible (%)	

Nota. Elaboración propia.

Para el presente caso de estudio, las variables de interés son la velocidad de rotación del eje de la turbina denominada N_{gp} y la temperatura de los gases de escape, denominada $T5$, los cuales varían en función del flujo másico del gas combustible m_f que ingresa al sistema de combustión de la turbina. Además, se tiene en cuenta la

temperatura de ingreso a la turbina $T1$, ya que esta variable de proceso afecta directamente el rendimiento de una turbina de gas.

Para confirmar las variables seleccionadas, utilizando las series de datos disponibles del comportamiento de la turbina, se realizó una exploración del coeficiente de correlación de Pearson, que valora la relación lineal entre variables continuas (ver Figura 3.6). Una relación es lineal cuando un cambio en una variable se relaciona con un cambio proporcional en otra variable. Se encontró que el flujo másico de gas combustible m_f y la velocidad de rotación de la TG Ngp tienen el coeficiente de correlación más alto, indicando un valor superior a 0,97.




Figura 3.6. Mapa de calor de correlación de Pearson de las variables seleccionadas.

También se analizó el coeficiente de correlación de Spearman, que valora la relación monótona entre dos variables continuas (ver Figura 3.7). En una relación de este tipo, las variables intentan cambiar al mismo tiempo, pero no precisamente a un ritmo constante. Se observa también una fuerte relación entre el flujo másico de gas combustible m_f y la velocidad de rotación de la TG Ngp .

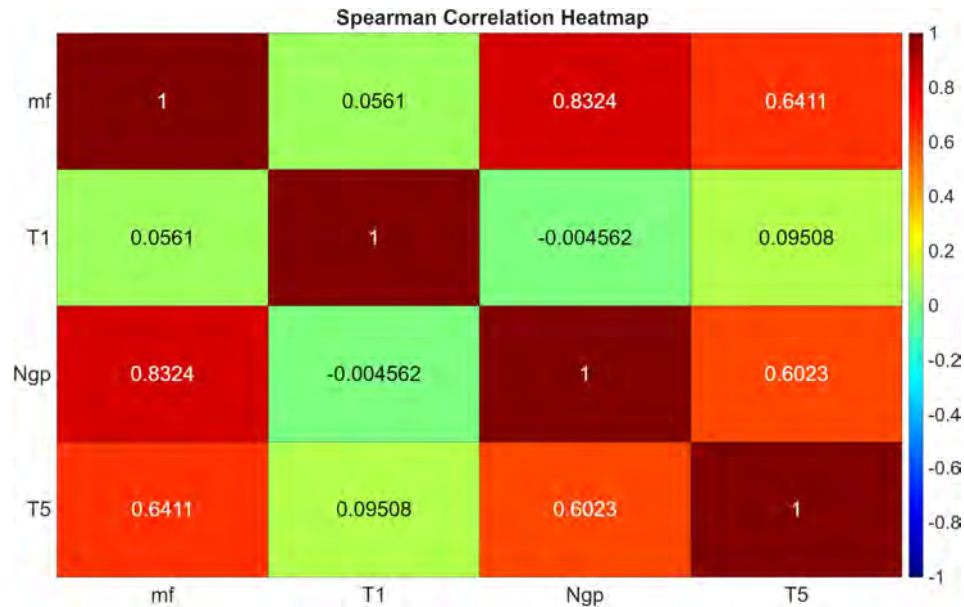


Figura 3.7. Mapa de calor de correlación de Spearman de las variables seleccionadas.

El proceso de identificación se desarrolla en dos partes. La primera es la identificación de la TG durante los periodos de arranque de la unidad. La segunda parte, corresponde a la identificación durante el comportamiento transitorio de la TG ante la demanda de potencia.

3.4 Identificación de la TG

Como se menciona en [57], las RNA se pueden clasificar en dinámicas y estáticas. Las RNA estáticas no tienen elementos de retroalimentación ni retardos; la salida se calcula directamente a partir de la entrada mediante conexiones de avance. En las RNA dinámicas, la salida depende no solo de la entrada actual a la RNA, sino también de las entradas, salidas o estados actuales o anteriores de la RNA.

Para la identificación del modelo de la variación de la velocidad de rotación de la TG bajo estudio se consideró el uso de una RNA no lineal auto regresiva con entradas exógenas (NARX), la cual es una red neuronal dinámica comúnmente usada para modelar series temporales. Esta red incluye conexiones de retroalimentación en alguna de sus capas.

En la ecuación que define el modelo NARX (ecuación 2.2), se observa que el valor futuro de la señal de salida dependiente es una función de los valores previos de las señales de salida y de entrada independiente. Los modelos NARX desarrollados utilizan como entradas únicamente variables en los intervalos de tiempo antecedentes. De hecho, la variable de entrada exógena en el intervalo de tiempo actual no es una entrada. Esta característica es destacable, ya que con este enfoque de modelado se pueden configurar herramientas de software para la optimización del control en tiempo real y el diagnóstico de sensores de TG, ejecutándose en paralelo a la planta.

Para la sintonía de los modelos NARX se utilizó el paquete Neural Network Tool-Box de MATLAB mediante el uso de grupos de datos de series temporales. Un modelo con estructura NARX fue entrenado para predecir las salidas en condiciones de arranque y el otro modelo fue entrenado para las condiciones de demanda de potencia de la TG.

Los modelos resultantes se obtuvieron tras realizar un estudio de sensibilidad de los parámetros NARX, es decir, el número de neuronas en la capa oculta, el número de conexiones de retroalimentación, y el número de puntos de tiempo retardados, con el fin de obtener el mejor modelo posible en cuanto a precisión de las tendencias y la métrica de la raíz del error cuadrático medio (RMSE), para las salidas de la red. Al mismo tiempo, la estructura de los modelos se mantuvo lo más simple posible, considerando el número mínimo requerido de neuronas y los puntos de tiempo retardados.

El valor de RMSE es una métrica estadística estándar utilizada en los trabajos de investigación para medir la performance de los modelos predictivos al igual que el error absoluto medio (MAE) [72]. Ambos evalúan el rendimiento, sin embargo, cuando el error tiene una distribución normal (gaussiana), lo cual es consistente con la variabilidad aleatoria que existe en procesos de mediciones de los sistemas de control y cuando hay suficientes muestras, el valor RMSE tiene ventajas sobre el valor de MAE para ilustrar mejor la variación del error [73].

De manera simplificada, el cálculo de los valores RMSE y MAE para n muestras de errores de un modelo, calculadas como e_i (para $i = 1, 2, \dots, n$), donde no se consideran las incertidumbres generadas por errores en la observación o el método utilizado para comparar el modelo y asumiendo que el conjunto de muestras de error no es sesgado, se pueden calcular mediante las expresiones [83]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (3.1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (3.2)$$

El valor MAE es adecuado para describir errores con distribución uniforme y cuando los errores del modelo tienden a tener una distribución normal, el valor RMSE es una métrica más adecuada. Hay que considerar, tal como afirman Chai y Draxler [73], que la mejor métrica estadística debe proporcionar no solo una medida del rendimiento, sino también una representación de la distribución del error.

3.4.1 Identificación de la TG durante el arranque

El arranque de la TG es el período de funcionamiento previo a que alcance condiciones de combustión estables. Para iniciar, las turbinas de gas necesitan una fuente externa, generalmente un motor eléctrico, el cual conduce a la turbina hasta que alcanza un porcentaje específico de la velocidad de diseño. Posteriormente, la turbina puede mantenerse sin el motor.

El procedimiento de arranque se puede dividir en cuatro fases: arranque inicial, velocidad de purga, encendido, y aceleración a velocidad de ralentí. En la fase de arranque en inicial, el eje del motor gira mediante el sistema de arranque sin alimentación de combustible. En la fase de purga, el combustible residual de las operaciones anteriores o de los intentos fallidos de arranque se purga del sistema. En esta fase, la velocidad de rotación se mantiene constante a un valor que garantiza un caudal másico adecuado a través de la cámara de combustión y de la turbina. Durante

el encendido, se alimenta con combustible a la cámara de combustión y se activa el encendido. Esto provoca el inicio de la ignición dentro de la cámara de combustión, seguido del encendido de todos los quemadores. Finalmente, en la fase de aceleración a ralentí, el caudal másico de combustible aumenta lo suficiente para alcanzar la velocidad de rotación de ralentí [22].

Los datos para el estudio de la identificación de la turbina de gas durante el arranque fueron tomados de manera experimental durante las maniobras de arranque, cubren el rango operacional completo de la turbina de gas en esta etapa, y tienen en cuenta todas las condiciones relacionadas con este tipo de maniobra transitoria, como el cierre de las válvulas de sangrado y el control de los álabes guía de ingreso de aire al compresor axial.

Para la TG objeto de estudio, dada sus características técnicas y tiempo de aceleración hasta la velocidad de sostenimiento, se ha considerado que la serie de datos temporales que se utiliza para entrenar el modelo NARX considere los valores de las variables en el rango operativo de la TG desde que hay ignición en la cámara de combustión y ya se ha desacoplado el motor de arranque de la turbina. La frecuencia de adquisición de datos es de 0.1 s.

La Tabla 3.3 muestra detalles sobre estos datos y el rango operativo de los parámetros de entrada y salida para el modelo. En la Figura 3.8 y 3.9 se muestra el comportamiento de las variables seleccionadas de entrada ($m_f, T1$), y de salida ($Ngp, T5$) para esta serie de datos.

Tabla 3.3
Conjunto de datos experimentales para la identificación durante el arranque.

Datos	Número muestras	Rango operacional de las entradas y salidas			
		$T1$ (deg F)	m_f (lb/h)	Ngp (rpm)	$T5$ (deg F)
Serie 1	1500	[99.4; 103.0]	[379.2; 1219.4]	[5886; 14963]	[570.5; 1134.1]

Nota. Elaboración propia




Figura 3.8. Comportamiento de las variables m_f y T_1 durante el arranque de la TG.




Figura 3.9. Comportamiento de las variables N_{gp} y T_5 durante el arranque de la TG.

El modelo NARX considerado para el sistema de estudio tendrá una estructura de múltiples entradas y una sola salida (MISO). Se ha decidido esta estructura teniendo en cuenta trabajos de investigación como el desarrollado por Bettocchi [74], donde se evidencia que, al utilizar una RNA para modelar turbinas de gas, hay una tasa de éxito comparable entre las estructuras MISO y MIMO. Por tanto, el algoritmo básico es una red de dos capas que tiene una conexión de retorno desde la capa de salida a la capa de entrada.

Durante el proceso de modelado, el algoritmo NARX puede diseñarse de forma flexible, dependiendo de diversos factores, como el número de neuronas, el tipo de funciones de activación y transferencia, y el método de entrenamiento del algoritmo. La estructura de lazo cerrado típica del modelo se muestra en la Figura 3.10.

El diagrama de bloques del modelo completo utilizado para la TG se muestra en la Figura 3.11. Se puede observar que se trata de 2 estructuras NARX en paralelo con 2 entradas y 2 salidas. Las variables de entrada son la temperatura de entrada del compresor $T1$ y el flujo másico del gas combustible m_f . Las variables de salida son la velocidad de rotación N_{gp} , y la temperatura de salida de los gases de escape de la TG $T5$.

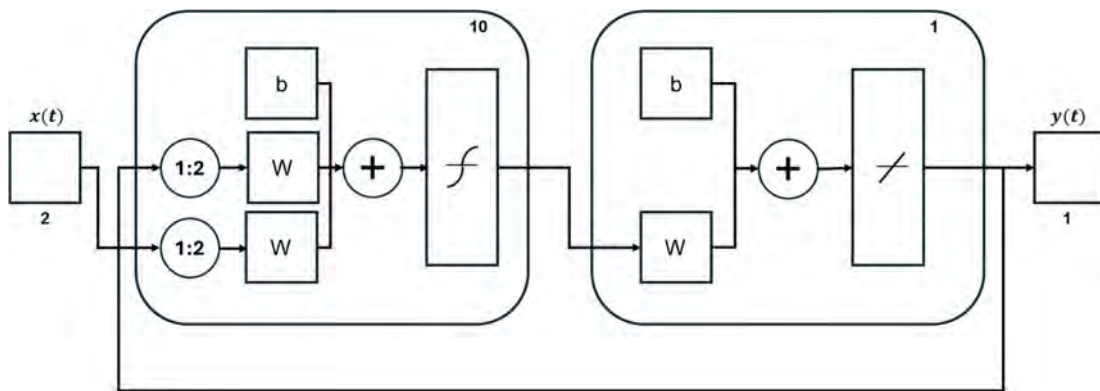


Figura 3.10. Estructura de lazo cerrado del modelo NARX.




Figura 3.11. Diagrama de bloques del modelo NARX completo.

3.4.1.1 Entrenamiento del modelo NARX de la TG durante el arranque

En general, el resultado del entrenamiento destaca que los modelos NARX pueden seguir el comportamiento físico durante la etapa transitoria de arranque de la turbina de gas. Además, se puede observar que los modelos NARX tienden a suavizar las variaciones rápidas.

Para el modelo NARX1, se obtuvieron los mejores resultados con una configuración de un retardo de 2 muestras para las entradas, 2 muestras para la salida, 10 neuronas en la capa oculta con una función de activación *tansig* y con una función de activación de la capa de salida *purelin*. La función de entrenamiento considerada fue *trainlm* (Levenberg-Marquardt). Los resultados se muestran en las Figuras 3.12 a 3.15.

Training Progress			
Unit	Initial Value	Stopped Value	Target Value
Epoch	0	100	100
Elapsed Time	-	00:00:00	-
Performance	21.2	1.03e-06	1e-08
Gradient	35.5	2.01e-05	1e-07
Mu	0.001	1e-06	1e+10
Validation Checks	0	0	10

Training Algorithms	
Data Division:	Random dividerand
Training:	Levenberg-Marquardt trainlm
Performance:	Mean Squared Error mse
Calculations:	MEX

Figura 3.12. Resultados del entrenamiento del modelo NARX1 (Serie 1).

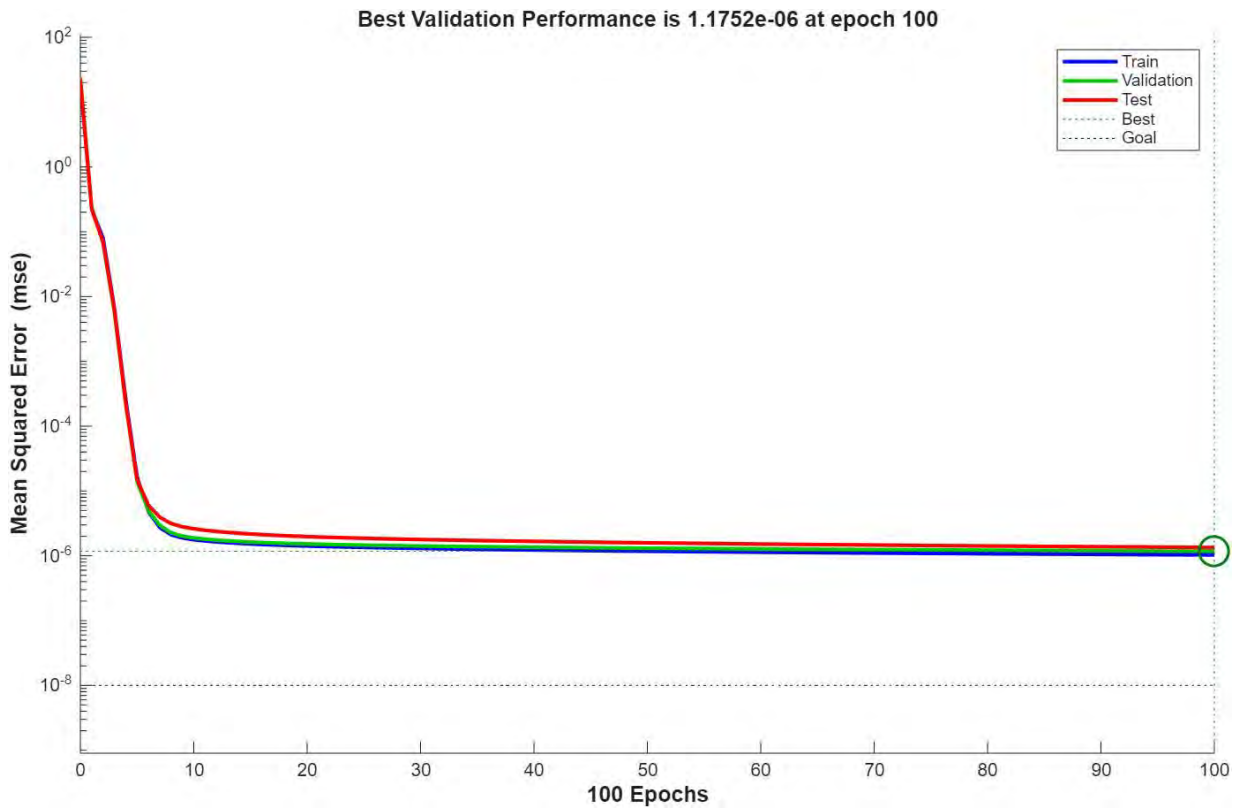


Figura 3.13. Performance de validación del modelo NARX1 (Serie 1).




Figura 3.14. Regresión del modelo NARX1 (Serie1).

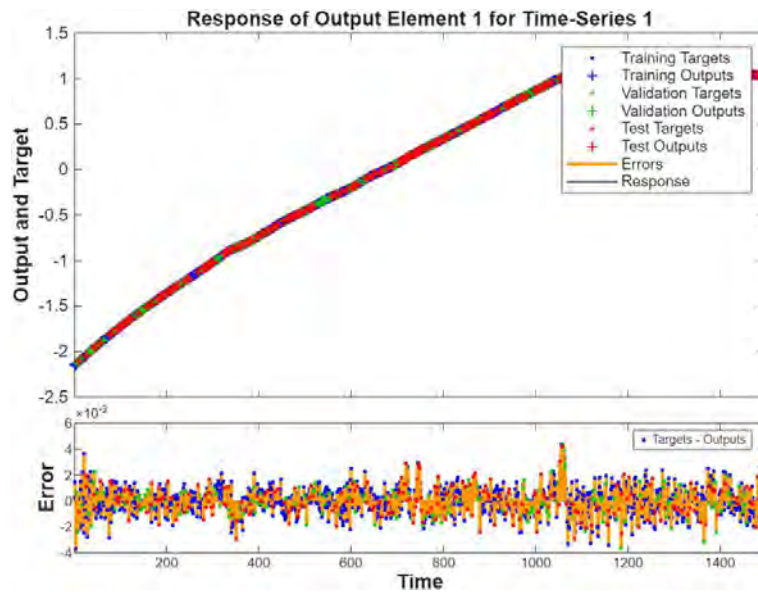


Figura 3.15. Respuesta de salida del modelo NARX1 (Serie 1).

Para el modelo NARX2, se consideró una configuración de red similar, con un retardo de 2 muestras para las entradas, 2 muestras para la salida, 10 neuronas en la capa oculta con una función de activación *tansig* y con una función de activación de la capa de salida *purelin*. Los resultados se muestran en las Figuras 3.16 a 3.19.

Training Progress			
Unit	Initial Value	Stopped Value	Target Value
Epoch	0	100	100
Elapsed Time	-	00:00:00	-
Performance	3.67	1.33e-05	1e-08
Gradient	11.2	3.17e-05	1e-07
Mu	0.001	1e-06	1e+10
Validation Checks	0	0	10

Training Algorithms	
Data Division:	Random dividerand
Training:	Levenberg-Marquardt trainlm
Performance:	Mean Squared Error mse
Calculations:	MEX

Figura 3.16. Resultados del entrenamiento del modelo NARX2 (Serie 1).

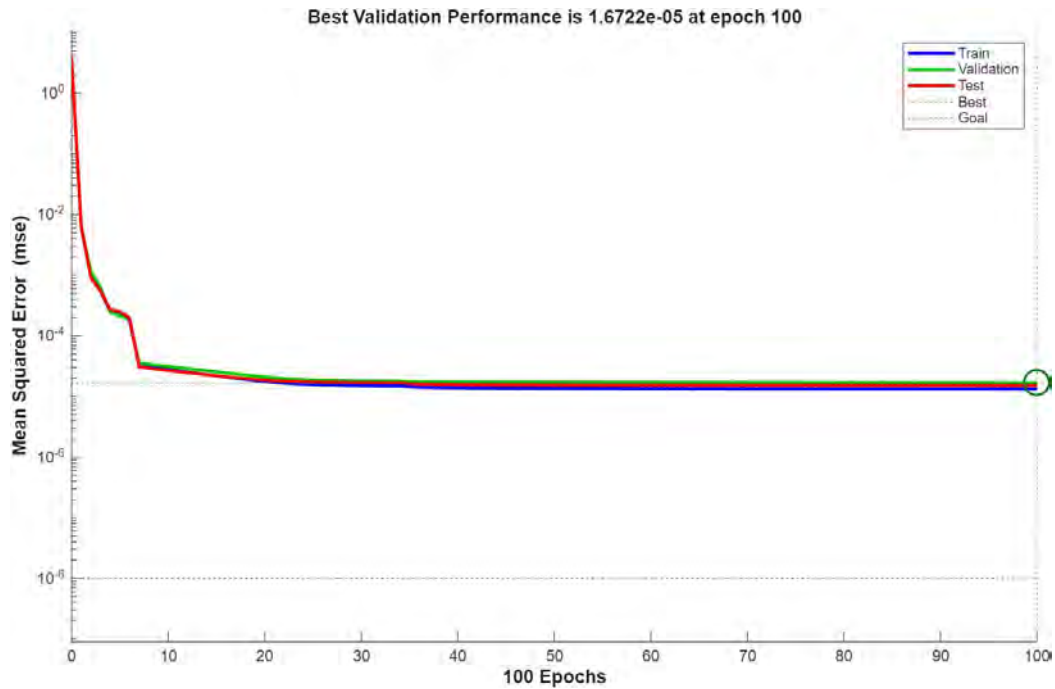


Figura 3.17. Performance de validación del modelo NARX2 (Serie 1).

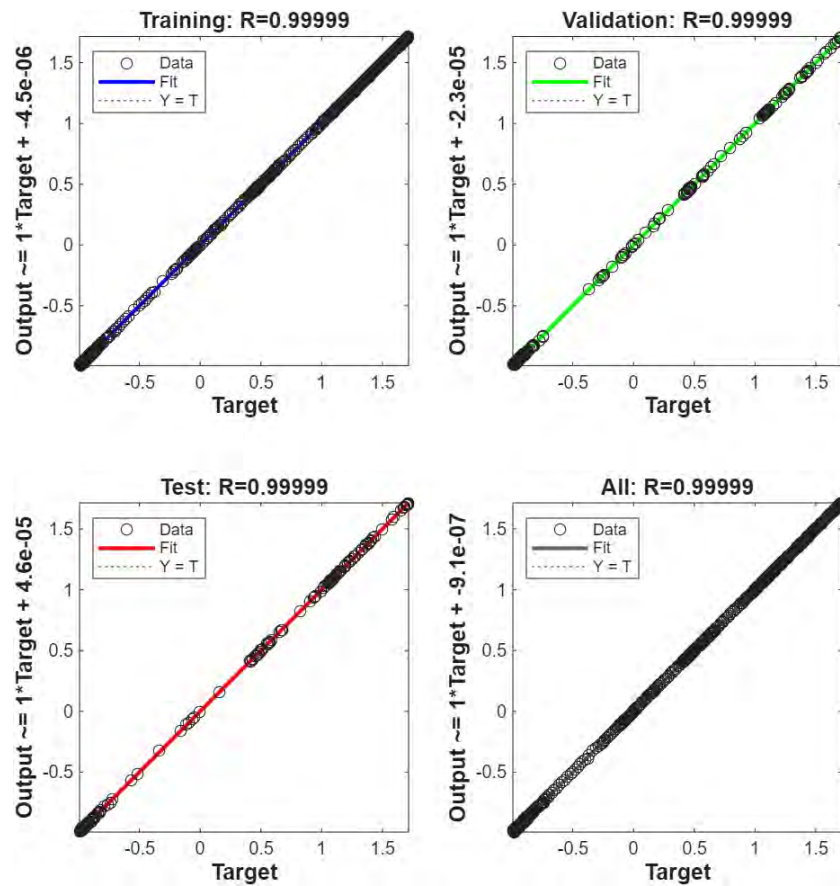


Figura 3.18. Regresión del modelo NARX2 (Serie 1).

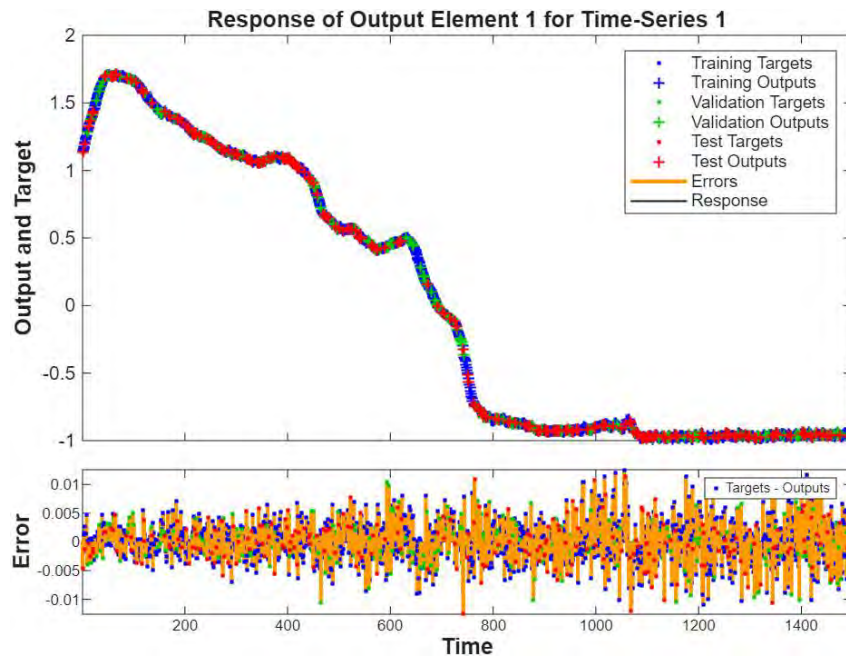


Figura 3.19. Respuesta de salida del modelo NARX2 (Serie 1).

3.4.1.2 Validación del modelo

Se compara la tendencia de la predicción del modelo NARX completo para las dos salidas (velocidad de rotación y temperatura de salida de la TG) con los datos operativos reales. En la Tabla 3.4 se resumen los resultados en términos de la métrica RMSE para evaluar la precisión del modelo de predicción.

Tabla 3.4
Valores RMSE del modelo para Ngp y $T5$ durante el arranque.

Variable	RMSE
Ngp	23.45 rpm (0.15%)
$T5$	15.12 degF (1.33%)

Nota. Elaboración propia.

En las Figuras 3.20 y 3.21 se exhiben la respuesta de la velocidad de rotación Ngp de la TG y la respuesta de la temperatura de los gases de escape $T5$ de la TG durante el arranque.




Figura 3.20. Respuesta de la velocidad de rotación N_{gp} de la TG durante el arranque.




Figura 3.21. Respuesta de la temperatura de los gases de escape T_5 de la TG durante el arranque.

3.4.2 Identificación de la TG durante la demanda de potencia

Los datos para el estudio de la identificación de la turbina de gas durante el comportamiento transitorio de la demanda de potencia fueron tomados de manera experimental durante maniobras de carga de la unidad hasta alcanzar la potencia necesaria en el rango operacional normal y tienen en cuenta las condiciones relacionadas con este tipo de maniobras. Por tanto, se ha incluido como referencia la tendencia de potencia entregada al sistema (en kW).

La serie de datos temporales que se utilizaron para entrenar el modelo NARX tienen un intervalo de tiempo para la adquisición de 0.1 s. La Tabla 3.5 muestra más detalles sobre el rango operativo de los parámetros de entrada y salida para el modelo.

Tabla 3.5
Conjunto de datos experimentales para la identificación durante la demanda de potencia.

Datos	Número muestras	Rango operacional de las entradas y salidas				
		T1 (deg F)	m_f (lb/h)	Ngp (rpm)	T5 (deg F)	P(kW)
Serie 2	3000	[81.5; 90.0]	[1088.1; 1763.8]	[100.0; 100.5]	[534.6; 1233.4]	[0.0; 2252.4]

Nota. Elaboración propia.

Las Figuras 3.22 a 3.26 exhiben el comportamiento de las variables seleccionadas de entrada y de salida para esta serie de datos. La variación de carga del turbogenerador es para una demanda de 0 a 2550 kW.




Figura 3.22. Comportamiento de la m_f durante la demanda de potencia.




Figura 3.23. Comportamiento de la T_1 durante la demanda de potencia.




Figura 3.24. Comportamiento de la Ngp durante la demanda de potencia.




Figura 3.25. Comportamiento de la $T5$ durante la demanda de potencia.


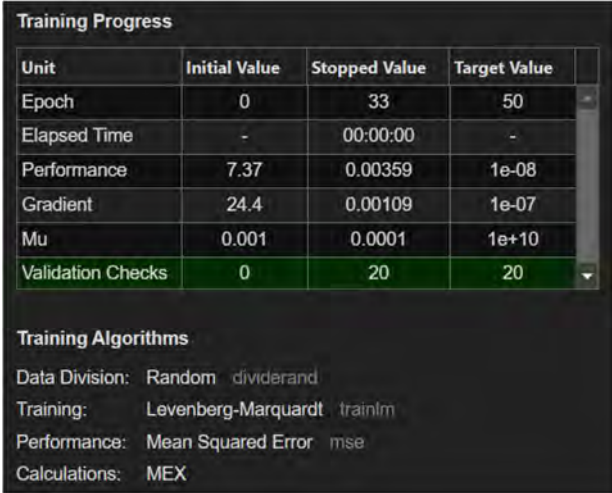


Figura 3.26. Comportamiento de la potencia aportada al sistema.

3.4.2.1 Entrenamiento del modelo NARX de la TG durante la demanda de potencia

Los resultados del entrenamiento destacan que los modelos NARX pueden seguir el comportamiento físico de las variables del sistema durante el transitorio de la demanda de potencia de una manera satisfactoria. Para el modelo NARX1, se obtuvieron los mejores resultados con una configuración de un retardo de 2 muestras para las entradas, 2 muestras para la salida, 20 neuronas en la capa oculta con una función de activación *tansig* y con una función de activación de la capa de salida *purelin*. La función de entrenamiento considerada fue *trainlm*. Los resultados numéricos del mismo se muestran en la Figura 3.27.

En la Figura a 3.28. se muestran los detalles de la mejor red resultante, basada en el rendimiento promedio de todas las estructuras entrenadas. También se muestra el rendimiento de la RNA durante el entrenamiento, la validación y la prueba. Como se puede observar, la iteración en la que el error de rendimiento de validación alcanzó su mínimo fue la 13. El error cuadrático medio del rendimiento en este punto es bajo. El entrenamiento continuó durante 20 iteraciones más antes de finalizar. En la Figura 3.29, se muestran las gráficas de regresión que indica la relación entre las salidas de la red y las salidas del sistema (objetivos). Para estas gráficas, el valor R es una indicación de la relación entre las salidas y los objetivos. Los valores de R para todos los gráficos indican alguna dispersión, pero son cercanos a 1, por lo tanto, el resultado para cada uno de los conjuntos de datos de entrenamiento, validación y prueba indica un ajuste aceptable.



Unit	Initial Value	Stopped Value	Target Value
Epoch	0	33	50
Elapsed Time	-	00:00:00	-
Performance	7.37	0.00359	1e-08
Gradient	24.4	0.00109	1e-07
Mu	0.001	0.0001	1e+10
Validation Checks	0	20	20

Training Algorithms

Data Division: Random dividerand
Training: Levenberg-Marquardt trainlm
Performance: Mean Squared Error mse
Calculations: MEX

Figura 3.27. Resultados del entrenamiento del modelo NARX1 (Serie 2).




Figura 3.28. Performance de validación del modelo NARX1 (Serie 2).

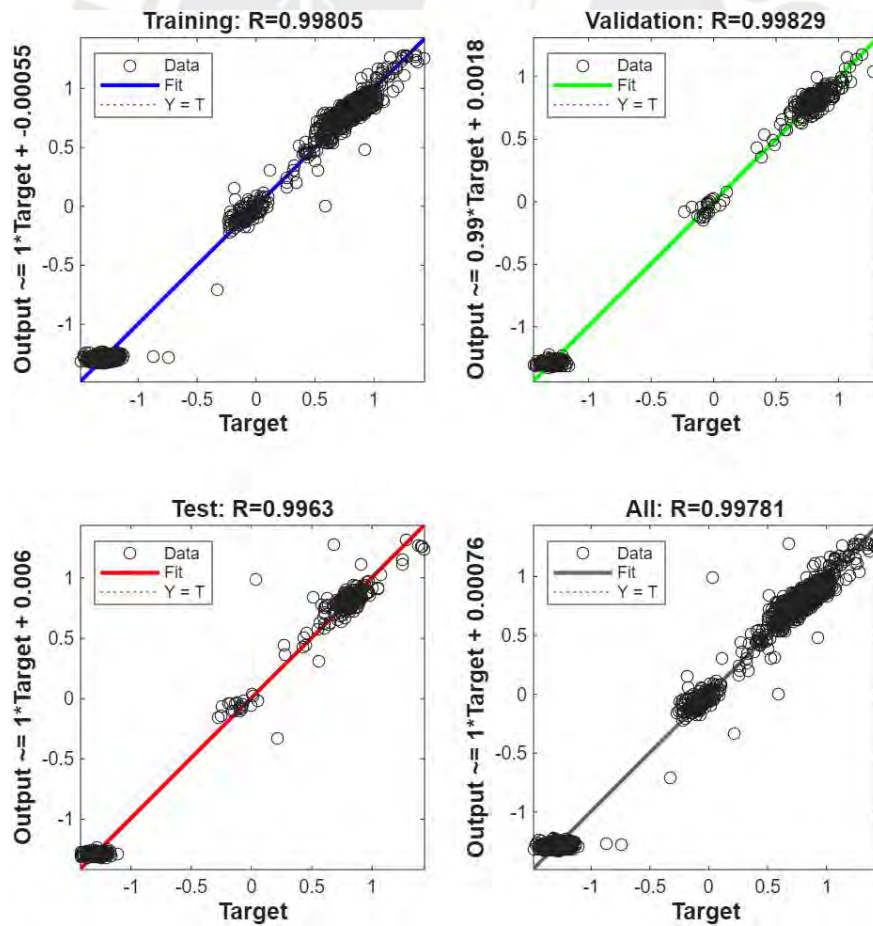


Figura 3.29. Regresión del modelo NARX1 (Serie2).




Figura 3.30. Respuesta de salida del modelo NARX1 (Serie 2).

Para el modelo NARX2, se consideró una configuración de red similar, con un retardo de 2 muestras para las entradas, 2 muestras para la salida, 20 neuronas en la capa oculta con una función de activación *tansig* y con una función de activación de la capa de salida *purelin*. Los resultados se muestran en las Figuras 3.31 a 3.34.

Training Progress			
Unit	Initial Value	Stopped Value	Target Value
Epoch	0	50	50
Elapsed Time	-	00:00:00	-
Performance	6.64	1.36e-05	1e-08
Gradient	21.8	5.45e-05	1e-07
Mu	0.001	1e-06	1e+10
Validation Checks	0	17	25

Training Algorithms	
Data Division:	Random dividerand
Training:	Levenberg-Marquardt trainlm
Performance:	Mean Squared Error mse
Calculations:	MEX

Figura 3.31. Resultados del entrenamiento del modelo NARX2 (Serie 2).




Figura 3.32. Performance de validación del modelo NARX2 (Serie 2).

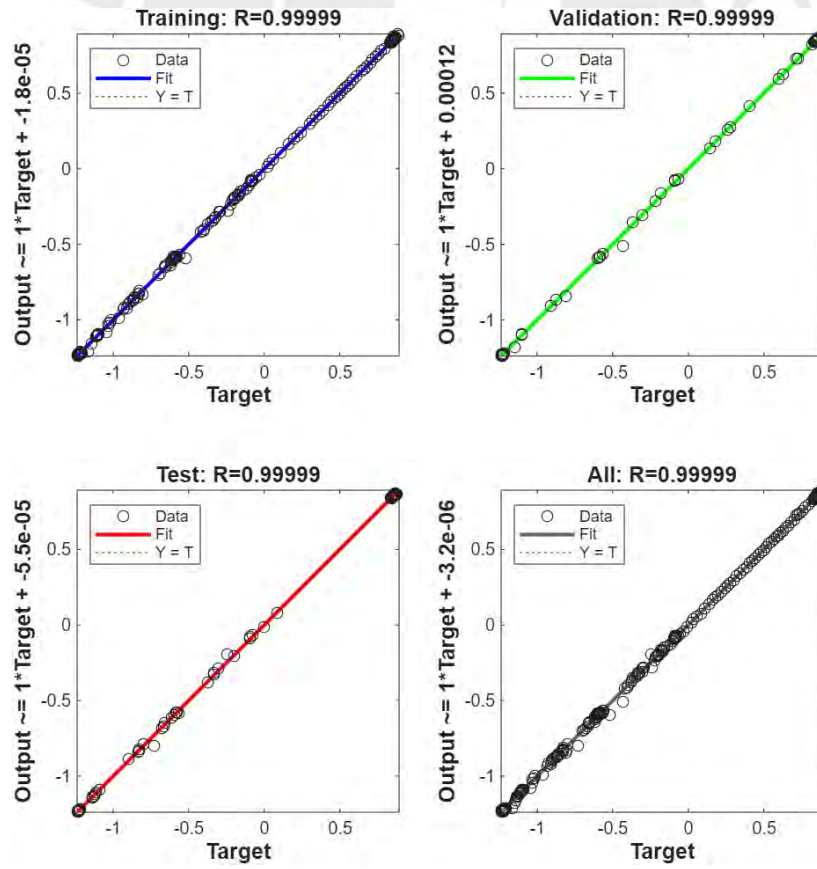


Figura 3.33. Regresión del modelo NARX2 (Serie2).




Figura 3.34. Respuesta de salida del modelo NARX2 (Serie 2).

3.4.2.2 Validación del modelo

Se comparó la tendencia temporal de la predicción del modelo NARX para las dos salidas (velocidad de rotación y temperatura de salida de la TG) con la de los datos reales registrados. En la Tabla 3.6 se hace un resumen de los resultados en términos de la métrica RMSE. Los resultados gráficos se exponen en las Figuras 3.35 y 3.36.

Tabla 3.6
Valores RMSE del modelo para N_{gp} y T_5 durante la demanda de potencia.

Variable	RMSE
N_{gp}	7.48 rpm (0.15%)
T_5	19.41 degF (1.33%)

Nota. Elaboración propia.




Figura 3.35. Respuesta de la velocidad de rotación N_{gp} de la TG durante la demanda de potencia.




Figura 3.36. Respuesta de la temperatura de escape T_5 de la TG durante la demanda de potencia.

3.5 Conclusiones

Se realizó la identificación del comportamiento dinámico de una TG industrial de un solo eje utilizado para la generación eléctrica, marca Solar modelo Centaur 50 de 4.6 MW, durante la fase de arranque y durante maniobras de demanda de potencia (variación de carga). Se construyeron modelos basados en RNA dinámicas NARX a partir de series de datos experimentales capturados durante la operación de la máquina. Se validaron los resultados de los modelos para sus valores correspondientes de velocidad rotacional y temperatura de salida de la TG (temperatura de escape) en función de la temperatura de ingreso y el caudal másico del gas combustible. En base a los resultados obtenidos se confirma que los modelos NARX son capaces de capturar y predecir la dinámica de la TG durante la etapa de arranque y durante maniobras de demanda de potencia incluso con perturbaciones en la carga.

Se observó que el error entre los valores medidos y simulados es aceptable, con una métrica RMSE menor al 1% para la velocidad rotacional y menor al 2% para la temperatura de salida de la TG. En general, es posible aseverar que los modelos NARX captan bien el comportamiento físico y la influencia de las variaciones en el conjunto de datos no es significativa. Se ha preferido la simplicidad en los modelos NARX durante el diseño y desarrollo. Se demuestra que en situaciones donde no se tiene información suficiente para un modelado basado en ecuaciones físicas complejas que describen el comportamiento de la TG, los modelos NARX como método de identificación de caja negra, son válidos para modelar la TG en diferentes escenarios de operación (arranque y variación de carga).

Se puede afirmar que los modelos NARX resultantes pueden reproducir un comportamiento inestable complejo y capturar la dinámica del sistema con una precisión aceptable. Por tanto, las RNA son una alternativa fiable a los métodos convencionales de identificación y modelado de sistemas. Además, los resultados de este enfoque de modelado, que utiliza como entradas las variables en los pasos de tiempo anteriores permiten la creación de herramientas de simulación que puede utilizarse para el control en tiempo real que requieren en su estructura modelos de la planta (como el control predictivo) y, en el diagnóstico de fallos en TG.

Capítulo 4: Desarrollo de controladores basados en RNA para el control de la velocidad de una TG

Introducción

En este capítulo, se implementa el sistema de control de la TG a partir del modelo propuesto por Rowen [17, 18]. Este modelo representa a una TG HDGT para estudios dinámicos basado en ecuaciones matemáticas simplificadas que describen su comportamiento físico y que ha sido utilizado en diversas investigaciones sobre estudios dinámicos y de estabilidad [72].

Considerando este sistema se desarrollan dos controladores avanzados basados en RNA: un controlador MPC, y un controlador de linealización por retroalimentación (NARMA-L2). También se desarrolla un controlador PID convencional como referencia. Para estos tres controladores se ajustan sus parámetros según los requisitos de diseño propuestos para controlar la velocidad de rotación de una TG.

Se utiliza el software Simulink de Matlab, el cual es un entorno de diagramas de bloque orientado al diseño de sistemas con modelos de múltiples dominios que permite simular antes de implementar en hardware y desplegar aplicaciones sin necesidad de escribir códigos mediante su paquete especializado Deep Learning Toolbox, que ofrece funciones y bloques para diseñar, implementar y simular RNA. Esta herramienta proporciona un marco de referencia útil para crear y utilizar RNA y permite visualizar e interpretar predicciones.

Finalmente, se realiza una comparación del rendimiento de los controladores: el regulador de velocidad original propuesto por Rowen, los controladores avanzados basados en RNA y el controlador PID.

4.1 Sistema de control de la TG

La planta basada en el modelo dinámico no lineal de una TG de un solo eje que fue desarrollado en base al modelo propuesto por Rowen se emplea para el diseño de

controladores avanzados basados en RNA y para el diseño de un controlador clásico PID. La Figura 4.1 exhibe el diagrama de lazo cerrado del sistema de control, el cual incluye la planta (TG), el controlador y la referencia aleatoria de la velocidad de rotación. El caudal másico de gas combustible y la velocidad de rotación son la entrada y la salida de la planta respectivamente. El controlador puede tener la estructura RNA-MPC, NARMA-L2, o PID.

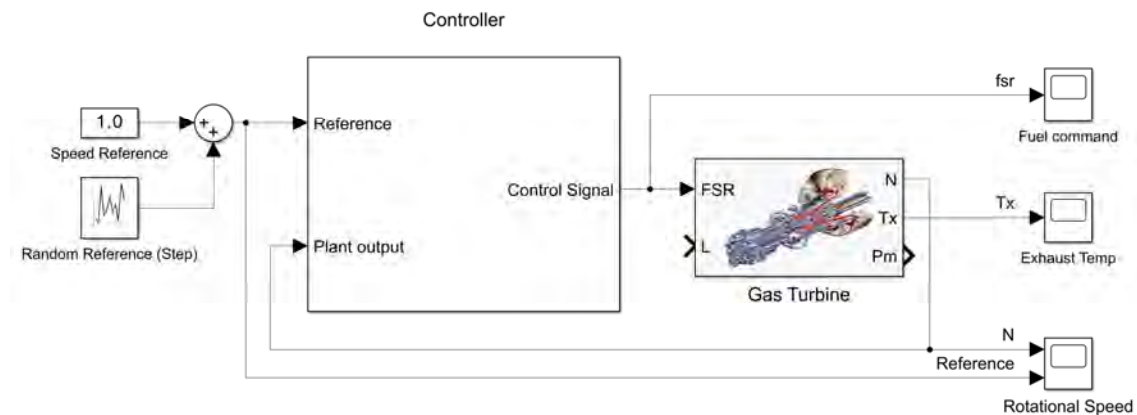


Figura 4.1. Diagrama del sistema de control de la velocidad de rotación de la TG.

En el modelo de Rowen, los componentes principales de la TG son; el compresor, la cámara de combustión y la turbina. La dinámica de la TG se describe mediante dos bloques caracterizados por funciones algebraicas. Tal como se muestra en la Figura 4.2, el bloque f_1 es una función del caudal de combustible y de la velocidad del rotor, y calcula la temperatura de escape de la TG, mientras que el bloque f_2 , es una función de las mismas variables que calcula el par o torque de salida de la TG. A estas funciones se les añaden retardos asociados con el transporte de gas, el proceso de combustión, y las constantes de tiempo de descarga del compresor.

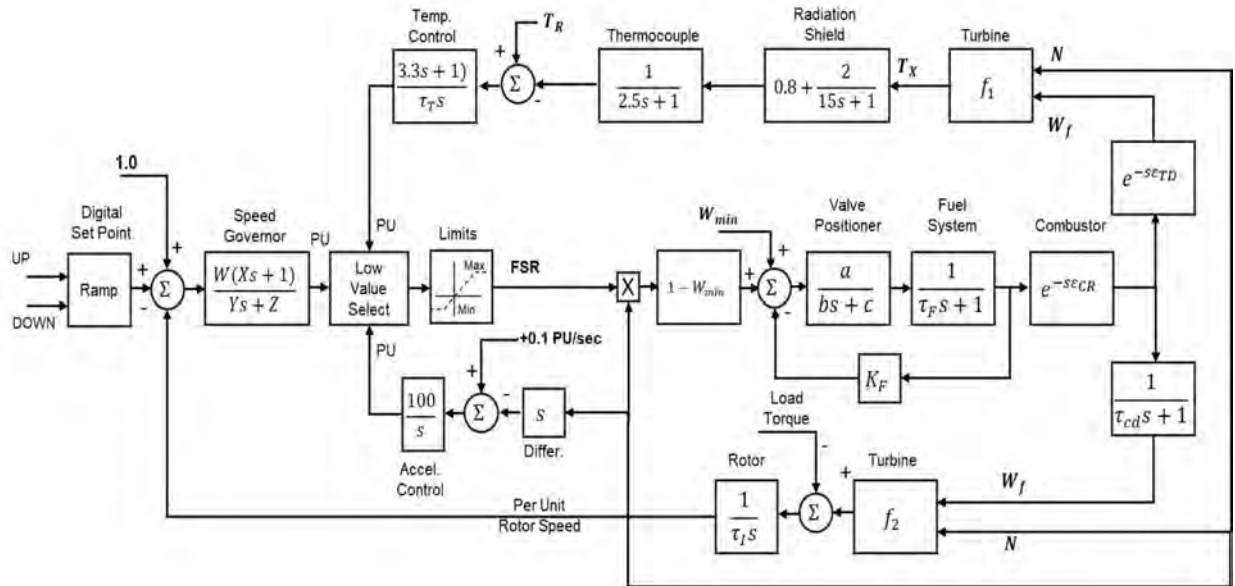


Figura 4.2. Modelo propuesto por Rowen para una TG de un solo eje y ciclo simple [17].

El modelo posee tres lazos de control: de velocidad o carga, de aceleración y de temperatura, que alimentan un diagrama de bloques que controla el flujo de gas combustible, mediante un selector de señales que elige la menor (Low Value Select o LVS). Esta señal se utiliza posteriormente en conjunto con la señal de velocidad del rotor, para definir las funciones de cálculo f_1 y f_2 respectivamente. En la Figura 4.3 se presenta este sistema de control.

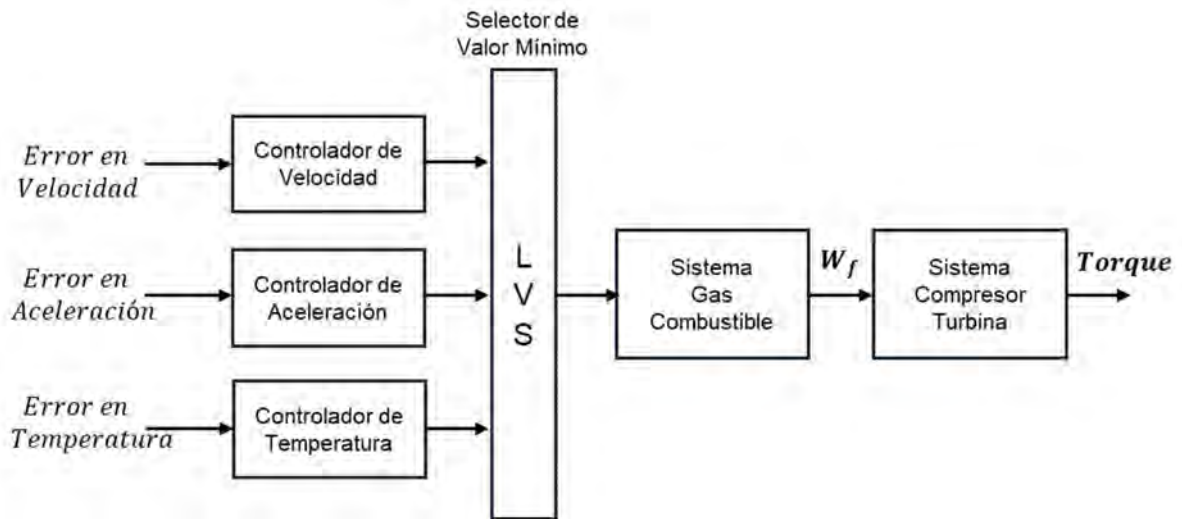


Figura 4.3. Representación del sistema de control del modelo propuesto por Rowen [90].

El lazo de control de velocidad corresponde al regulador principal, el cual es denominado “regulador de velocidad” y puede operar en modo de caída (droop) o en modo isócrono. Su representación en diagrama de bloques se exhibe en la Figura 4.4. El regulador de velocidad opera en función al error de velocidad. Su salida es proporcional al error (modo de caída) o la tasa de cambio de la salida es proporcional al error (modo isócrono). Esta señal de salida es enviada al selector de valor mínimo.




Figura 4.4. Diagrama de bloques del lazo de control de velocidad.

En el modelo también se considera un lazo de “control de aceleración”, el cual es utilizado para limitar la tasa de aceleración del rotor durante el arranque y para evitar el exceso de velocidad del generador en caso de una pérdida repentina de carga [75]. Durante la operación normal actúa como un controlador secundario para reducir el flujo de gas combustible y limitar la tendencia a la sobre velocidad. La velocidad es diferenciada para obtener la aceleración y luego comparada con la aceleración de referencia. El error se envía al controlador y la salida de este se envía al selector de valor mínimo. El diagrama de bloques del lazo de control de la aceleración se exhibe en la Figura 4.5.




Figura 4.5. Diagrama de bloques del lazo de control de la aceleración.

El lazo de “control de temperatura” limita la salida de regulación del gas combustible hacia la TG en función de la temperatura de los gases de escape. La temperatura se mide mediante una serie de termopares con protectores de radiación. El diagrama de bloques con sus funciones de transferencia se muestra en la Figura 4.6. Cuando la temperatura de salida supera la temperatura de referencia, la diferencia se vuelve negativa y comienza a disminuir la salida del controlador de temperatura. Cuando la salida del controlador de temperatura es inferior a la salida del regulador principal, el valor anterior pasa por el selector de valor mínimo para limitar la salida de control, y la unidad pasa a funcionar en modo de control de temperatura.

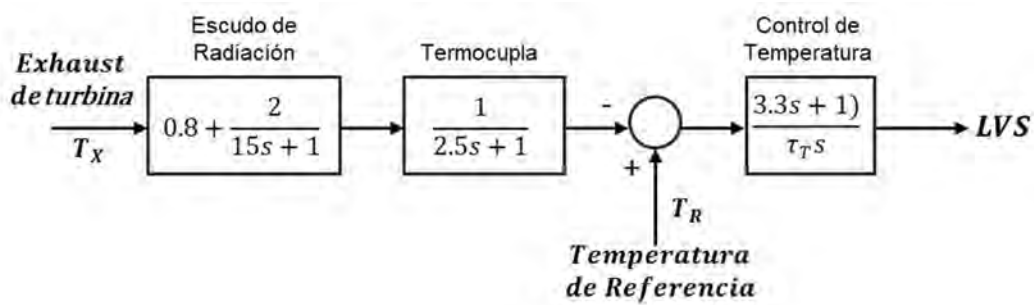


Figura 4.6. Diagrama de bloques del lazo de control de temperatura.

Cabe mencionar que en el modelo de Rowen las unidades en las que se representan las variables son por unidad de magnitud o p.u. (per unit), a excepción de la variable de temperatura expresada en °F. La unidad p.u. significa que se expresa una cantidad como fracción de un valor de referencia, o valor base, de la misma cantidad. Es una forma de normalizar los valores, facilitando los cálculos y haciéndolos más consistentes en diferentes configuraciones. Es un valor adimensional que representa la dependencia entre el valor real y el valor base elegido.

Como caso de estudio se eligió una TG de un solo eje y ciclo simple para la generación eléctrica marca GE modelo 5001M de 18.2 MW de potencia. Los parámetros que caracterizan esta unidad se muestran en las Tablas 4.1 y 4.2.

La variable principal de salida del sistema de control es la velocidad de rotación del eje, producida por la energía del gas combustible y que a su vez determina la generación de electricidad a partir de la potencia mecánica que entrega al generador.

Tabla 4.1
 Datos de la TG para la generación eléctrica objeto de estudio.

Modelo	Velocidad nominal (rpm)	Potencia nominal (MW)	Temperatura Nominal (degF)	Frecuencia nominal (Hz)
5001M	5100	18.2	955	50

Nota. Adaptado de [32].

Tabla 4.2
 Parámetros de caracterización de la TG.

Parámetro	Descripción	Valor
W	Ganancia = 1 / droop (p.u. MW / p.u. velocidad)	16.7
X	Constante de tiempo de avance del gobernador (s)	0.6
Y	Constante de tiempo de retardo del gobernador (s)	1.0
Z	Modo del gobernador (1=Droop, 0=Isócrono)	1
MAX	Límite de demanda superior (p.u.)	1.5
MIN	Límite de demanda inferior (p.u.)	-0.1
a	Constante de posicionador de válvula de combustible	1
b	Constante de posicionador de válvula de combustible	0.05
c	Constante de posicionador de válvula de combustible	1
W_{\min}	Flujo mínimo de gas combustible	0.23
T_F	Constante de control de tiempo de combustible (s)	0.4
K_F	Retroalimentación del sistema de combustible	0
E_{CR}	Tiempo de retardo de reacción de combustión (s)	0.01
E_{TD}	Retardo de la turbina y el escape(s)	0.02
T_{CD}	Constante de tiempo de volumen de descarga del compresor (s)	0.1
T_R	Temperatura nominal de escape de la turbina (°F)	955
T_T	Constante de integración del controlador de temperatura (°F)	450
f_1	$T_x = T_R - 700*(1-W_F) + 550*(1-N)$ (°F)	
f_2	$1.3*(W_F - 0.23) + 0.5*(1-N)$	
T_i	Inercia = $2*H$ (s), H = constante de inercia	16.2

Nota. Adaptado de [32]. Los parámetros W, X, Y, Z corresponden al regulador de velocidad original propuesto por Rowen.

La temperatura de salida de la TG y la aceleración del eje, son variables secundarias [17]. Por lo tanto, el sistema de control de la TG se representa como se indica en la Figura 4.7. En este sistema, la velocidad del eje se controla regulando la apertura de la válvula del gas combustible, el posicionador de la válvula mueve el actuador a una posición que corresponde al valor de referencia [76]. El modelo de la válvula se puede representar como un sistema de primer orden más tiempo muerto [77, 78]. Para el presente estudio su modelado ya se encuentra incluido dentro del modelo de Rowen desarrollado.

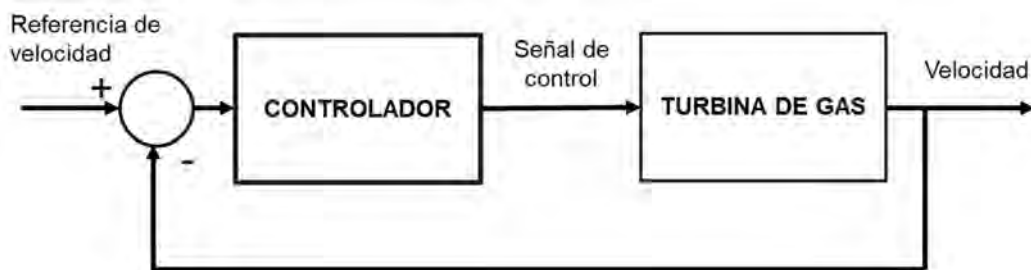


Figura 4.7. Diagrama de bloques del sistema de control de la velocidad de rotación de la TG.

El diagrama de bloques detallado, basado en el modelo de Rowen, para la TG seleccionada, que contiene las funciones de transferencia de cada subsistema fue implementado en Simulink y ha sido nombrado “gt5001m”, como se exhibe en la Figura 4.8.

El diagrama de bloques implementado incluye los controladores originales propuestos por Rowen de velocidad, de temperatura, y de aceleración [16,17], los cuales se exhiben en la Figura 4.9.

La señal de control que determina el flujo del combustible es el comando o referencia de carrera de la válvula de combustible (fuel stroke reference FSR) que establece la cantidad de combustible suministrada a la TG para cumplir los requerimientos de carga y velocidad. Las respuestas de los sistemas de control de la temperatura de salida de los gases de escape (T_x), y de la velocidad de rotación de la TG (N) se presentan en las Figuras 4.10 a 4.12.

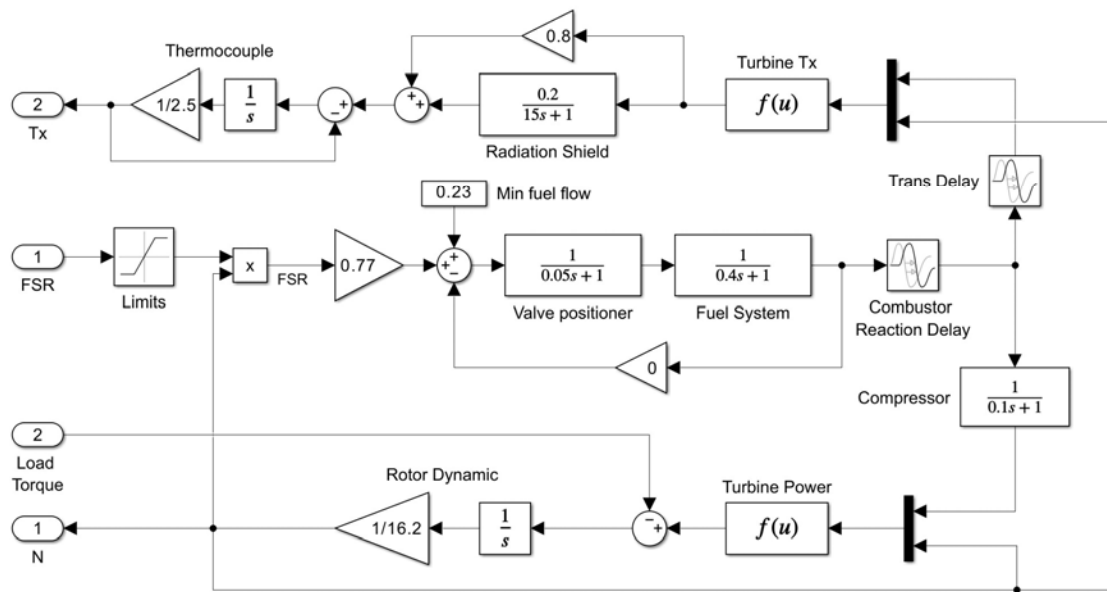


Figura 4.8. Diagrama de bloques basado en el modelo de Rowen de la TG.

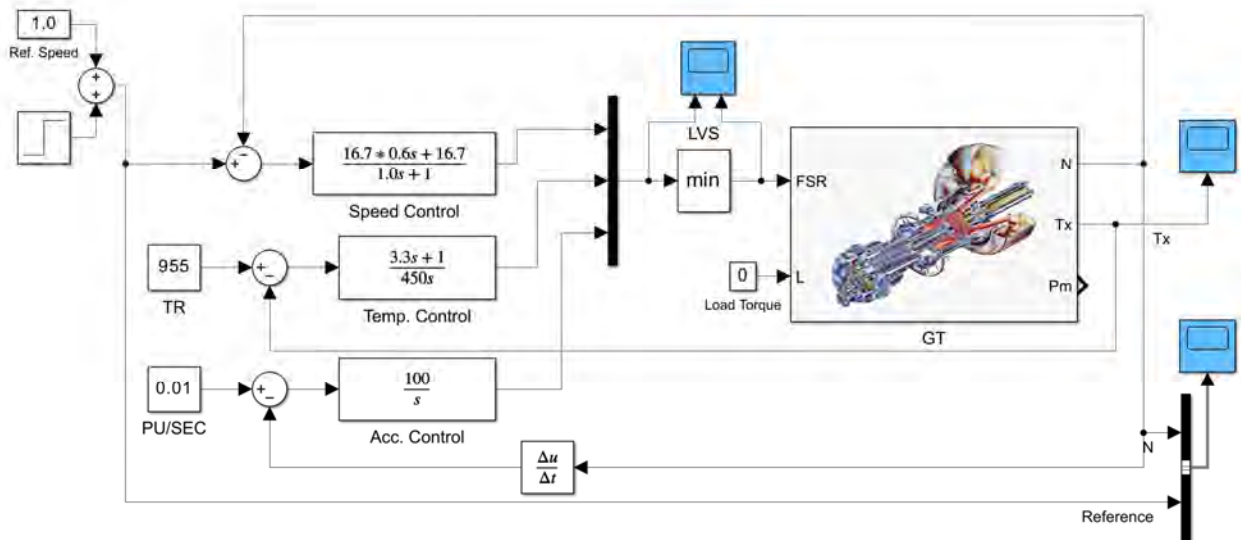


Figura 4.9. Diagrama en Simulink del modelo y controladores propuestos por Rowen de la TG.




Figura 4.10. Valores para la selección del comando del flujo del gas combustible.




Figura 4.11. Respuesta de la temperatura de los gases de escape de la TG.




Figura 4.12. Respuesta de la velocidad de rotación de la TG frente a un cambio de consigna.

La velocidad nominal de la TG es de 5100 rpm, equivalente en unidades normalizadas a 1.0 p.u. El objetivo del control es mantener la velocidad de rotación de la TG a un valor constante, expresado en unidades normalizadas p.u., cuando la entrada del sistema de control cambia con una referencia aleatoria (función escalón). El cambio en la referencia se ajustó a +5.0 del punto de consigna, es decir a 1.05 p.u.

Dada la dinámica de la TG objeto de estudio, el objetivo del diseño para este estudio es lograr una respuesta satisfactoria frente a la entrada de referencia, para cada uno de los controladores con los detalles contenidos en la Tabla 4.3.

Tabla 4.3
Especificaciones de diseño de los controladores.

Condición	Valor
Tiempo de subida (T_r)	< 5 s
Tiempo de estabilización (T_s)	< 25 s
Sobre impulso máximo (M_p)	< 15 %
Error en estado estacionario (E_{ss})	< 5 %

Nota. Elaboración propia.

El tiempo de subida, es el tiempo requerido para que la señal de respuesta aumente del 10 % al 90 % del valor final (su valor de consigna). El tiempo de estabilización o de establecimiento, es el tiempo transcurrido para que la señal de respuesta alcance y permanezca dentro de una banda de error ($\pm 5\%$) del valor final. El tiempo de pico, es el tiempo transcurrido para que la señal de respuesta alcance su primer valor máximo. El sobre impulso máximo es el valor pico máximo de la curva de respuesta, medido a partir de la respuesta deseada del sistema. El error de estado estacionario es la diferencia entre la salida y la referencia que persiste tras la desaparición de las condiciones transitorias.




Figura 4.13. Respuesta típica a una señal de prueba estándar del regulador de velocidad propuesto por Rowen.

Como punto de partida, se observa en la Figura 4.13, que para el regulador de velocidad propuesto por Rowen, la respuesta del sistema presenta un tiempo de subida de 1.46 segundos, un tiempo de estabilización de 7.04 segundos, un sobre impulso máximo de 14.06 %, y, un error en estado estacionario de 2.77 %.

4.2 Fundamentación de la ley de control a utilizar (RNA)

Las RNA se han utilizado ampliamente para resolver diversas tareas, especialmente en casos donde las soluciones algorítmicas convencionales resultan subóptimas y menos eficientes [79, 80], también, se han aplicado en la identificación y el control de procesos dinámicos.

La capacidad de aproximación universal del perceptrón multicapa lo convierte en una opción para modelar sistemas no lineales e implementar controladores no lineales de propósito general [63]. Las soluciones basadas en RNA se emplean ampliamente en diversas tareas y aplicaciones prácticas [81].

Las RNA son aproximadores universales de funciones dinámicas [82], constituyendo un modelo empírico no lineal que simboliza datos de entrada y salida. Una RNA puede replicar el modelo de un proceso mediante el aprendizaje de patrones de un conjunto de datos suficientemente amplio, requiriendo escaso conocimiento previo sobre su estructura [83]. Su capacidad para anticipar con precisión respuestas futuras ha sido evidenciada en una variedad de investigaciones [23, 53, 54, 84].

Tal como se realizó en el capítulo de identificación mediante RNA, se adoptará una RNA dinámica debido a las ventajas que ofrece en variables descritas mediante series de tiempo. Las RNA dinámicas difieren de las RNA estáticas debido a que disponen de elementos de retroalimentación con retardos y pueden predecir variables objetivo con mayor precisión. Entre las RNA dinámicas, se destacan las de estructura no lineal auto regresiva con entrada exógena (NARX), este tipo de redes son consideradas como aceptables predictores de la dinámica de sistemas no lineales debido a su vertiginosa convergencia y su superior capacidad de generalización [85]. Dos estrategias de control avanzado, que utilizan las RNA dinámicas para la predicción y el control, son el control MPC [37, 38] y el control de linealización por retroalimentación (NARMA-L2) [57].

El uso de RNA para el control de sistemas suele constar de 2 etapas: identificación del sistema, y diseño del controlador. En la etapa de identificación del sistema se desarrolla el modelo de la RNA de la planta que se requiere controlar. En la etapa de diseño del controlador, se utiliza el modelo de la RNA de la planta para diseñar (o entrenar) el controlador. La fase de identificación del sistema es idéntica, pero la fase de diseño del controlador es diferente para cada arquitectura. En el control MPC, el modelo de la planta se utiliza para predecir el comportamiento dinámico futuro de la planta y un algoritmo de optimización se utiliza para obtener la entrada de control que optimiza el desempeño futuro [40]. Para el control NARMA-L2, el controlador es una reorganización del modelo de la planta [57].

Cada controlador tiene sus propias fortalezas y debilidades, por lo cual, se puede afirmar que un controlador puede ser más adecuado y funcionar mejor dependiendo de la aplicación en la que se implementa. Entre las características principales de los controladores neuronales considerados, se puede mencionar [57]:

- El controlador RNA-MPC utiliza un modelo de una RNA para predecir las respuestas futuras de la planta frente a señales de control. El optimizador calcula las señales de control que optimizan el desempeño futuro de la planta. El modelo de planta basado en la RNA se entrena sin conexión por lotes. Sin embargo, el controlador requiere de una gran cantidad de cómputos en línea, ya que se ejecuta un comando de optimización en cada periodo de muestreo para computar la entrada de control óptimo.
- El controlador NARMA-L2 requiere un menor consumo computacional, es simplemente una reorganización del modelo de la planta basado en una RNA, que se entrena fuera de línea. El único cómputo en línea es un paso directo a través del controlador de la RNA. La desventaja de este método es que la planta debe estar en forma complementaria o ser capaz de aproximarse mediante un modelo de forma complementaria.

A continuación, se realiza el diseño y se simulan los sistemas de control que utilizan controladores RNA-MPC, NARMA-L2 y PID.

4.3 Controlador predictivo basado en RNA (RNA-MPC)

Como se mencionó en el capítulo previo, el controlador MPC que hace uso de RNA es una técnica de control avanzada que integra la capacidad de predicción del MPC con las ventajas de aproximación a funciones no lineales que poseen las RNA. Este enfoque es especialmente valioso para su aplicación en sistemas complejos, no lineales y difíciles de modelar como son las TG.

El controlador RNA-MPC funciona en tres pasos. Primero se modela el sistema a controlar con una RNA mediante el entrenamiento. La RNA recibe el estado actual y las acciones pasadas y predice la salida o comportamiento futuro del sistema en un horizonte de tiempo. El segundo paso consiste en resolver el problema de

optimización para encontrar la secuencia de acciones que minimizan una función de costo. En el tercer paso, se aplica la acción óptima de control. Este proceso se repite posteriormente en cada ciclo con el nuevo estado del sistema.

Como ventajas del enfoque RNA-MPC se tiene: mayor precisión en sistemas no lineales, reducción de la carga computacional, posibilidad de implementación en tiempo real, y, adaptabilidad a cambios dinámicos. Entre los desafíos que se presentan al utilizar esta técnica, están: requiere datos de entrenamiento representativos, puede comprometer cumplir las restricciones si el modelo no es entrenado adecuadamente, y la validación y robustez del modelo neuronal son críticas.

4.3.1 Diseño del controlador RNA-MPC

Para el diseño del controlador MPC, se debe determinar el modelo basado en una RNA de la planta (identificación del sistema). Luego, el controlador utiliza el modelo de la planta para pronosticar el comportamiento futuro [57]. La RNA se entrena utilizando el error entre la salida de la planta y la salida de la RNA. El modelo de la planta utiliza las salidas y entradas previas de la planta para predecir los valores posteriores. Como ya se mencionó, esta RNA se ha implementado con la herramienta Deep Learning Toolbox. El controlador MPC basado en una RNA se implementó en Simulink-MATLAB y se exhibe en la Figura 4.14.

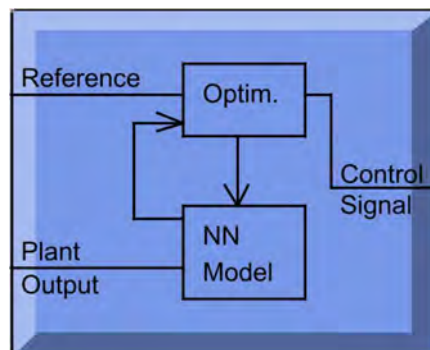


Figura 4.14. Diagrama del controlador MPC basado en una RNA [57].

4.3.1.1 Identificación del sistema MPC basado en una RNA

Previo al diseño del controlador, se debe realizar la identificación del sistema y desarrollar el modelo de la RNA de la planta. El algoritmo de optimización emplea estas predicciones para determinar las entradas de control que optimizan el desempeño futuro. El diagrama resultante de la identificación de la planta “gt5001m” con todos los parámetros ajustados para la generación de datos y el entrenamiento del modelo de la RNA del sistema se muestra en la Figura 4.15.

The screenshot displays the 'Plant Identification' software interface, organized into three main sections:

- Network Architecture:** Includes 'Size of Hidden Layer' (20), 'Sampling Interval (sec)' (0.1), 'No. Delayed Plant Inputs' (2), and 'No. Delayed Plant Outputs' (2). A checkbox for 'Normalize Training Data' is present and unchecked.
- Training Data:** Includes 'Training Samples' (2000), 'Maximum Plant Input' (0.5), 'Minimum Plant Input' (-0.5), 'Maximum Interval Value (sec)' (0.4), and 'Minimum Interval Value (sec)' (0.2). On the right, 'Limit Output Data' is checked, with 'Maximum Plant Output' (1.1) and 'Minimum Plant Output' (0.9). A 'Simulink Plant Model' field contains 'gt5001m' and a 'Browse' button.
- Training Parameters:** Includes 'Training Epochs' (500) and 'Training Function' (trainlm). Checkboxes for 'Use Current Weights', 'Use Validation Data', and 'Use Testing Data' are all checked.

Buttons for 'Generate Training Data', 'Import Data', and 'Export Data' are located at the bottom of the interface.

Figura 4.15. Diagrama con los resultados de la identificación de sistema de la TG para el diseño del controlador MPC.

Como se observa, los valores mínimo y máximo de entrada de la planta (demanda de combustible) son -0.5 y 0.5 p.u. Para la salida de la planta (velocidad de rotación), los valores mínimo y máximo son 1.1 y 0.9 p.u., respectivamente. Estos valores fueron escogidos mediante la exploración sistemática del modelo “gt5001m” desarrollado, aplicando señales de prueba y midiendo la respuesta de la planta.

Antes de la etapa de entrenamiento de la RNA, se generaron 2000 conjuntos de datos para la entrada y salida de la planta, considerando los intervalos mínimo y máximo de 0.2 y 0.4 s, respectivamente. El tamaño de la capa oculta es de 20 neuronas y el número de entradas y salidas retardadas de la planta se ajustaron a 2. El intervalo de muestreo se estableció en 0.1 s. El entrenamiento se realizó según la función de entrenamiento *trainlm*. Una vez finalizado el entrenamiento, se muestran las respuestas del modelo de la planta resultante (Figura 4.16 a 4.22).




Figura 4.16. Datos generados para el entrenamiento del controlador RNA-MPC.

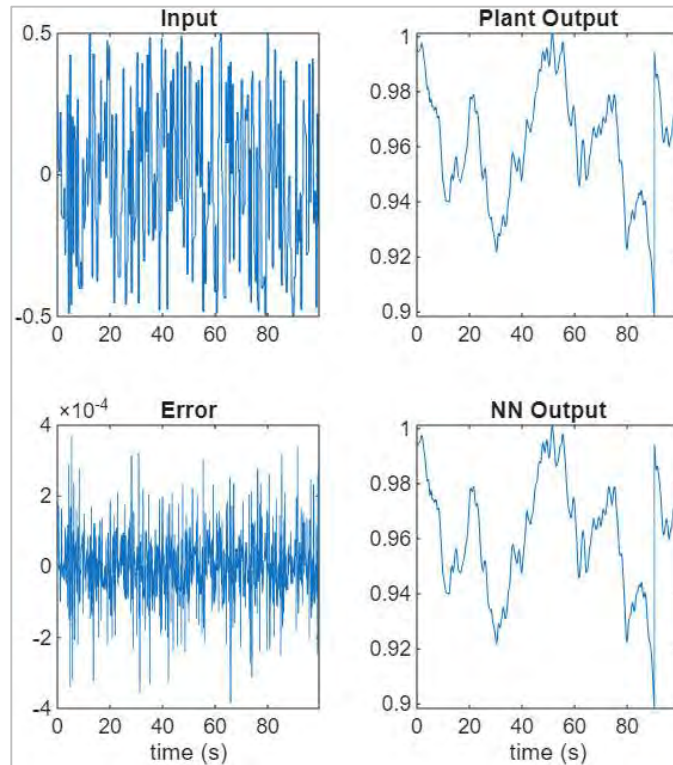


Figura 4.17. Datos de entrenamiento del controlador RNA-MPC.




Figura 4.18. Datos de validación del controlador RNA-MPC.

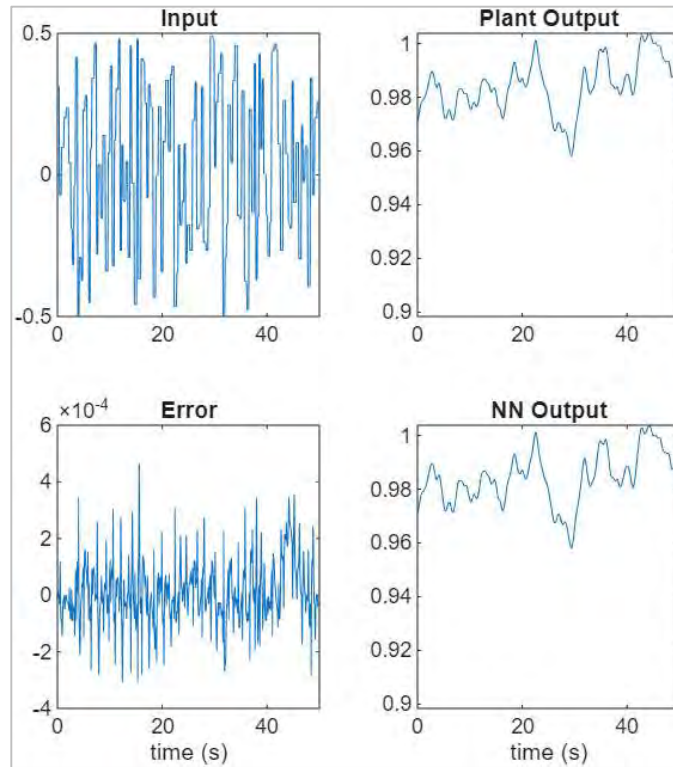



Figura 4.19. Datos de prueba del controlador RNA-MPC.



(a)

(b)

Figura 4.20. Resultados: (a) entrenamiento, (b) performance alcanzado del controlador RNA-MPC.




Figura 4.21. Regresión de la RNA entrenada del controlador RNA-MPC.




Figura 4.22. Estructura de la RNA del modelo de la planta del controlador RNA-MPC.

Se observa que los datos de salida de la RNA para la validación y prueba siguen bastante bien la salida de la planta, el error cuadrático medio (mse) alcanzado para los datos de entrenamiento es de 9.44×10^{-9} y para los datos de validación es de 1.03×10^{-9} ; por tanto, se puede afirmar que los resultados son satisfactorios.

4.3.1.2 Ajuste de los parámetros del controlador RNA-MPC

Luego del proceso de identificación del sistema, se diseña el controlador predictivo mediante una metodología heurística y tomando en cuenta trabajos de investigación revisados [86, 87, 88], se definen los horizontes del controlador N_2 y N_u los cuales fueron ajustados a 10 y 2, respectivamente. N_1 se fijó en el valor 1 por defecto. El factor de ponderación ρ y el parámetro de búsqueda α se ajustaron a 0.005 y 0.001 respectivamente.

La función del parámetro α es controlar la optimización especificando la reducción del rendimiento necesaria para una optimización exitosa. El número de iteraciones del algoritmo de optimización en cada tiempo de muestreo se ajustó a 2. El algoritmo de optimización puede utilizar diferentes rutinas de minimización lineal. La rutina de minimización seleccionada para este diseño es “*csrchbac*” disponible en la herramienta de Simulink-MATLAB. Esta rutina es una minimización unidimensional que utiliza el método de búsqueda con retroceso (backtracking search routine).

En la Figura 4.23 se exhibe un diagrama del controlador RNA-MPC diseñado con el ajuste de sus parámetros.

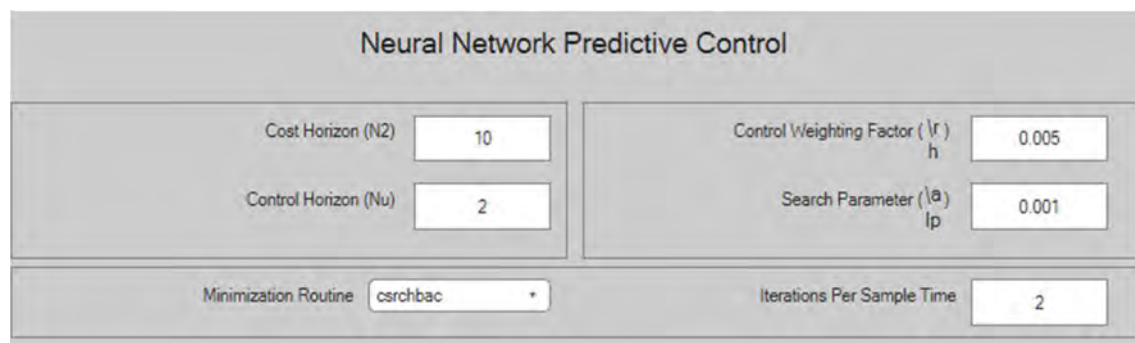


Figura 4.23. Diagrama del controlador RNA-MPC con los parámetros ajustados.

4.3.2 Simulación del controlador RNA-MPC

Posterior al ajuste de los parámetros del controlador, se realiza la simulación del controlador RNA-MPC. En la Figura 4.24 se presenta el diagrama de bloques del sistema de control de lazo cerrado de la TG.

En el bloque controlador MPC se observan el modelo de la planta basado en RNA y el bloque de optimización, que como se mencionó anteriormente considera la rutina de búsqueda con retroceso. Esta rutina se inicia con un multiplicador de paso 1 y retrocede hasta obtener una reducción aceptable en el rendimiento. En el primer paso, utiliza el valor del rendimiento en el punto actual y un multiplicador de paso 1. También utiliza el valor de la derivada del rendimiento en el punto actual para obtener una aproximación cuadrática de la función de rendimiento en la dirección de búsqueda. El mínimo de aproximación cuadrática se convierte en un punto óptimo tentativo y se evalúa el rendimiento en este punto. Si el rendimiento no se reduce lo suficiente, se obtiene una interpolación cúbica y el mínimo de esta interpolación se convierte en el nuevo punto óptimo tentativo. Este proceso se repite hasta obtener una reducción suficiente en el rendimiento.

La rutina es descrita con detalle por Dennis y Schnabel en [89] y se utiliza como búsqueda lineal predeterminada para los algoritmos cuasi-Newton que son métodos de optimización numérica que buscan encontrar los máximos y mínimos de funciones.

Los resultados de la simulación con la respuesta del sistema completo se exhiben en las Figura 4.25 a 4.27.

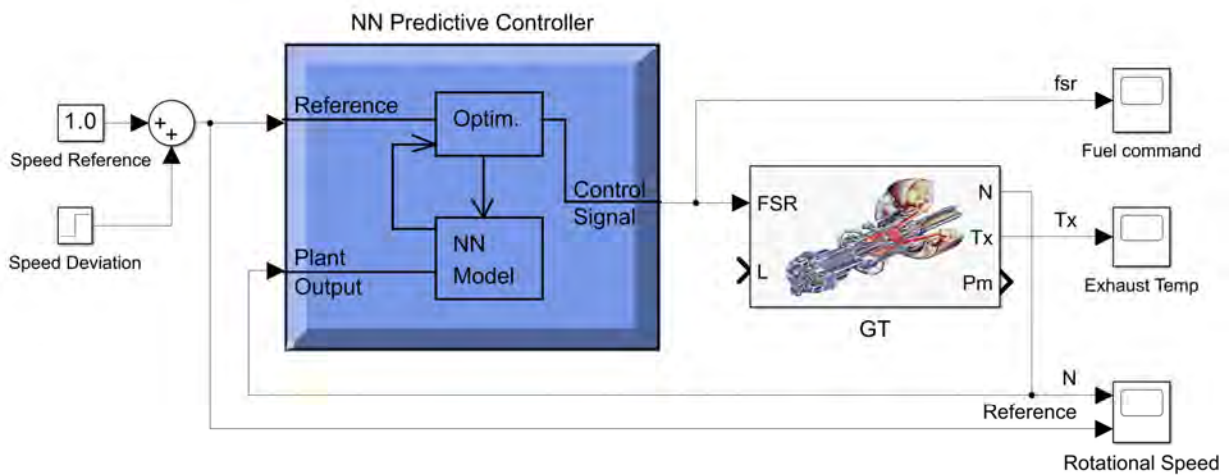


Figura 4.24. Diagrama del sistema de control en lazo cerrado de la TG con el controlador RNA-MPC.




Figura 4.25. Señal de control (FSR) del controlador RNA-MPC.




Figura 4.26. Respuesta del sistema de control de la temperatura de salida de la TG con el controlador RNA-MPC.




Figura 4.27. Respuesta del sistema de control de la velocidad de rotación de la TG con el controlador RNA-MPC frente a una entrada escalón de la velocidad de 0.05 p.u.

Los parámetros de performance obtenidos por el controlador RNA-MPC a la respuesta de escalón son presentados en la Tabla 4.4.

Tabla 4.4.
Performance obtenida del sistema de control con el controlador RNA-MPC.

Condición	Valor
Tiempo de subida	1.71 s
Tiempo de establecimiento	2.49 s
Sobre impulso	3.30 %
Error de estado estacionario	0.22 %
Estabilidad en lazo cerrado	Estable

Nota. Elaboración propia.

Se observa que este controlador se destaca por su rapidez de respuesta; sin embargo, la salida del sistema presenta un sobre impulso, y mantiene un error de estado estacionario.

4.4 Controlador de linealización por retroalimentación (NARMA-L2)

El controlador de linealización por retroalimentación o de media móvil autorregresiva no lineal (NARMA-L2) se fundamenta en una técnica de control basada en RNA que permite manejar sistemas no lineales complejos mediante una aproximación de su dinámica interna. Convierte un sistema dinámico no lineal en un sistema que puede ser controlado como si fuera lineal, contribuyendo al diseño de estrategias de control efectivas.

De manera simplificada se puede afirmar que este controlador opera en tres pasos: primero, utiliza una RNA para modelar la dinámica del sistema en la forma NARMA; seguidamente, la RNA es entrenada para predecir la salida futura del sistema en función de entradas y salidas pasadas; y, finalmente, esta RNA se utiliza para generar señales de control que optimicen el comportamiento del sistema.

Como ventajas de este enfoque se tiene: excelente manejo de sistemas no lineales, alta precisión en la predicción de las salidas, adaptabilidad a cambios dinámicos, y facilidad de implementación en tiempo real. Entre sus desafíos se puede mencionar: requiere entrenamiento intensivo de la RNA, es sensible a la calidad de los datos de entrenamiento, y puede tener dificultades en sistemas con alta variabilidad.

4.4.1 Diseño del controlador NARMA-L2

En Simulink-MATLAB, se implementó el controlador NARMA-L2, listo para ser parametrizado. Al igual que con el controlador RNA-MPC, el uso de NARMA-L2 consta de dos pasos: la identificación del sistema y el diseño del controlador. En la Figura 4.28 se muestra el diagrama de bloques del controlador NARMA-L2.

En la etapa de identificación se desarrolló un modelo basado en una RNA de la planta. El proceso de entrenamiento es similar al ya descrito previamente. En la Figura 4.29 se muestra el diagrama de bloques de la identificación de la planta para el sistema de control de la TG “gt5001m” que utiliza el controlador NARMA con todos los parámetros ajustados para generar datos y entrenar el modelo basado en una RNA.

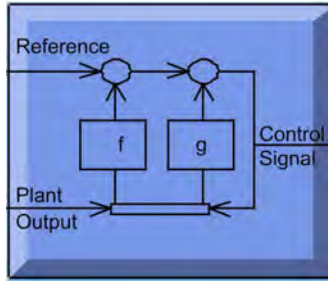


Figura 4.28. Diagrama de bloques del controlador NARMA-L2 [43].

Los valores mínimo y máximo de la entrada de la planta que corresponden a los valores para la señal de referencia de la carrera de la válvula del gas combustible (FSR) son -0.4 y 0.4 p.u. Para la salida de la planta (velocidad de rotación), los valores mínimo y máximo son 1.1 y 0.9 p.u., respectivamente.

The screenshot shows the 'Plant Identification - NARMA-L2' configuration window. It is divided into three main sections:

- Network Architecture:**
 - Size of Hidden Layer: 20
 - Sampling Interval (sec): 0.1
 - No. Delayed Plant Inputs: 2
 - No. Delayed Plant Outputs: 2
 - Normalize Training Data
- Training Data:**
 - Training Samples: 5000
 - Maximum Plant Input: 0.4
 - Minimum Plant Input: -0.4
 - Maximum Interval Value (sec): 0.4
 - Minimum Interval Value (sec): 0.2
 - Limit Output Data
 - Maximum Plant Output: 1.1
 - Minimum Plant Output: 0.9
 - Simulink Plant Model: Browse
 - File name: gt5001m
 - Buttons: Generate Training Data, Import Data, Export Data
- Training Parameters:**
 - Training Epochs: 200
 - Training Function: trainlm
 - Use Current Weights
 - Use Validation Data
 - Use Testing Data

Figura 4.29. Diagrama de bloques de la identificación de sistema de la TG para el controlador NARMA-L2.

Previo a la etapa de entrenamiento de la RNA, se generaron 5000 conjuntos de datos para la entrada y la salida de la TG, considerando los valores de intervalo mínimo y máximo de 0.2 y 0.4 s. Estos datos se generaron utilizando la opción integrada en el

bloque, la cual permite generar datos de entrenamiento aplicando una serie de entradas aleatorias al modelo de Simulink de la planta.

La capa oculta y el número de entradas y salidas retardadas de la planta se ajustaron a 20 y 2, respectivamente. El intervalo de muestreo se fijó en 0.1 s. El entrenamiento se realizó según la función de entrenamiento seleccionada *trainlm*. Luego de finalizar el entrenamiento, se observó que los resultados del entrenamiento del modelo de la RNA de la TG son satisfactorios. Estos resultados se presentan en las Figuras 4.30 a 4.34.




Figura 4.30. Datos generados para el entrenamiento del controlador NARMA-L2.

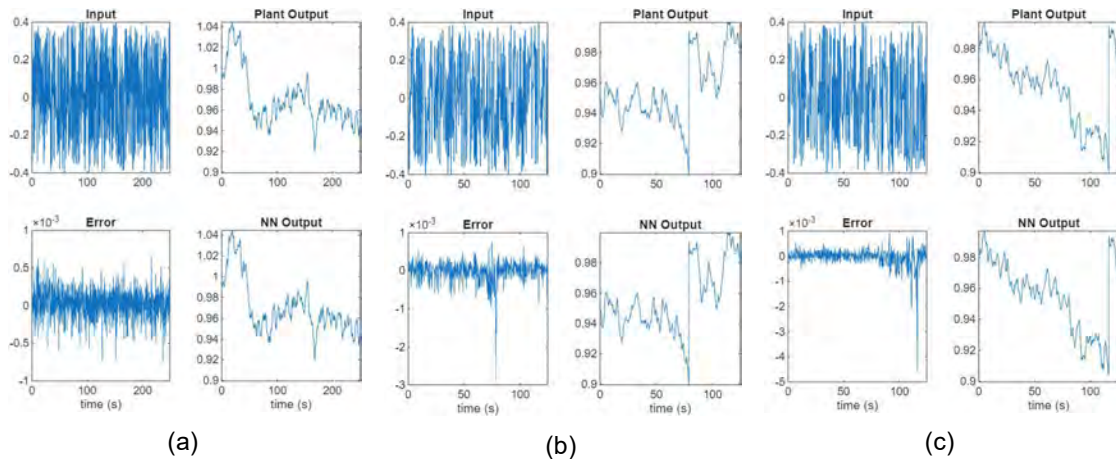


Figura 4.31. Datos de: (a) entrenamiento, (b) validación, (c) prueba del controlador NARMA-L2.




Figura 4.32. Resultados: (a) entrenamiento, (b) performance alcanzada con el controlador NARMA-L2.




Figura 4.33. Regresión de la RNA entrenada del controlador NARMA-L2.

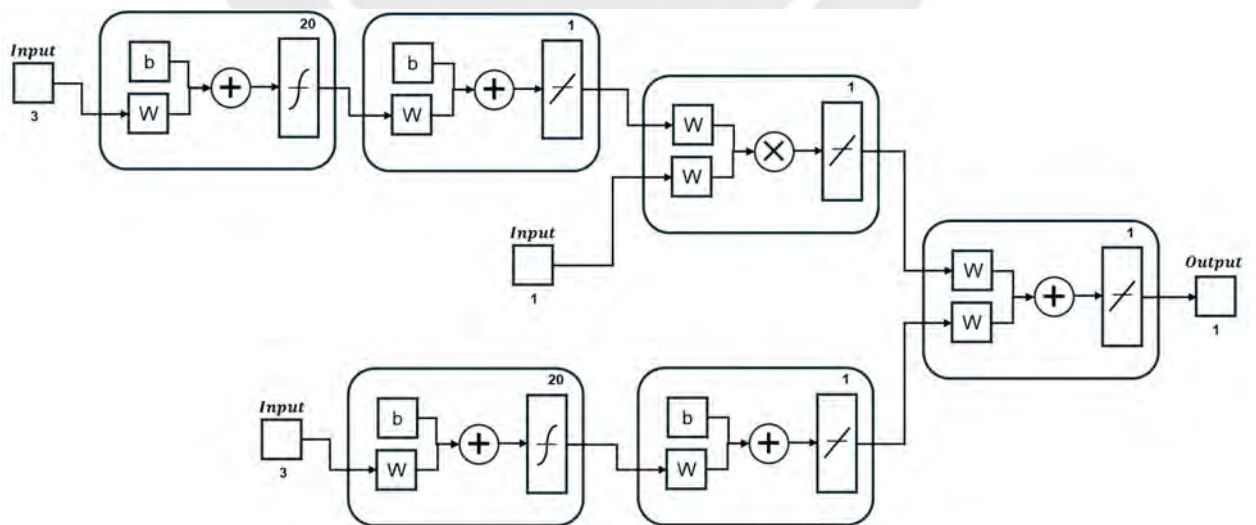


Figura 4.34. Estructura de la RNA del controlador NARMA-L2.

El diagrama de lazo cerrado del sistema de control de la TG con el controlador NARMA-L2 se exhibe en la Figura 4.35.

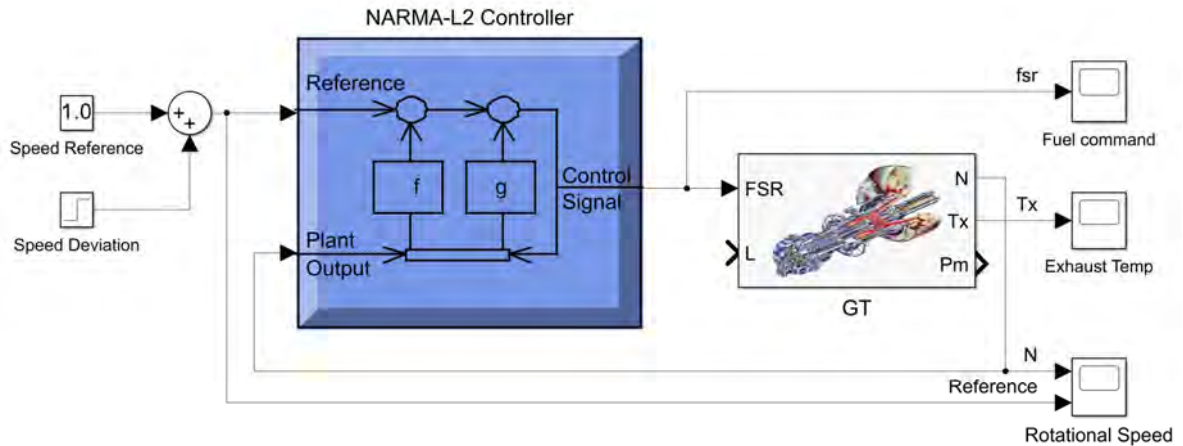


Figura 4.35. Diagrama de bloques del sistema de control de lazo cerrado de la TG con el controlador NARMA-L2

4.4.2 Simulación del sistema de control de la TG con el controlador NARMA-L2

En la etapa de simulación del controlador NARMA-L2, se ejecutó el sistema de control de lazo cerrado para observar la respuesta del sistema completo. El resultado obtenido muestra que el controlador NARMA-L2 puede seguir con mayor precisión la referencia de entrada al sistema y la reacción del controlador no presenta sobre impulsos. Los resultados de simulación del sistema de control de la TG con la respuesta del sistema completo se presentan en la Figura 4.36 a 4.38.




Figura 4.36. Señal de control (FSR) del controlador NARMA-L2.




Figura 4.37. Respuesta del sistema de control de la temperatura de salida con NARMA-L2.




Figura 4.38. Respuesta del sistema de control de la velocidad de rotación de la TG con el controlador NARMA-L2 frente a una entrada escalón de velocidad de 0.05 p.u.

Los parámetros de performance obtenidos por el controlador NARMA-L2 frente a la respuesta escalón se exhiben en la Tabla 4.5.

Tabla 4.5
Performance obtenida por el controlador NARMA-L2.

Condición	Valor
Tiempo de subida	2.94 s
Tiempo de establecimiento	4.31 s
Sobre impulso	0.16 %
Error de estado estacionario	0.00 %
Estabilidad en lazo cerrado	Estable

Nota. Elaboración propia.

Se observa que este controlador cumple con las condiciones de diseño propuestas. Se destaca porque logra que la variable a controlar (velocidad de rotación de la turbina de gas) tenga una respuesta rápida, además, prácticamente no presenta sobre impulso y tampoco presenta error de estado estacionario.

4.5 Controlador PID

El controlador PID es uno de los más utilizados en la industria por su simplicidad, robustez y eficacia para regular sistemas dinámicos. Su estructura se basa en tres componentes que responden al error actual (P), al acumulado del error en el tiempo (I) y a la tasa de cambio del error (D).

Las ventajas de este controlador son: fácil de implementar y ajustar; compatible con sistemas lineales y algunos no lineales; buen rendimiento en la mayoría de las aplicaciones industriales; y, amplia disponibilidad comercial. Como desafíos para su uso se tiene: requiere sintonía adecuada para evitar oscilaciones o lentitud; la acción derivativa puede amplificar el ruido si no es filtrada previamente; y, puede saturarse el término integral si no se aplica alguna estrategia anti-windup.

4.5.1 Diseño del controlador PID

El diagrama de bloques del controlador PID se encuentra implementado en Simulink-MATLAB (ver Figura 4.39). Este bloque de función se basa en un algoritmo PID cuya estructura interna es de forma paralela y sus parámetros se pueden ajustar de manera manual o automática de acuerdo con algoritmos de ajuste basados en dos métodos: función de transferencia y respuesta en frecuencia.




Figura 4.39. Bloque del control PID de Simulink-MATLAB.

El objetivo del ajuste es lograr un buen equilibrio entre rendimiento y robustez, manteniendo la estabilidad del lazo cerrado. El ajuste se realizó de forma que el sistema de lazo cerrado siga los cambios de referencia, suprima las perturbaciones lo más rápido posible y su salida se mantenga acotada para una entrada acotada. Además, el diseño del lazo debe tener suficientes márgenes de ganancia y de fase para considerar errores de modelado o variaciones en la dinámica del sistema [21].

Según el algoritmo, en la primera etapa del ajuste, se diseña un controlador inicial seleccionando un ancho de banda para lograr el equilibrio entre rendimiento y robustez con base en la respuesta en frecuencia del lazo abierto del modelo linealizado. Cuando el tiempo de respuesta, el ancho de banda, o el margen de fase se modifican interactivamente mediante la interfaz del sintonizador PID, el algoritmo calcula las nuevas ganancias del PID. Este proceso continúa hasta obtener el controlador PID deseado [46]. En correspondencia con el algoritmo, su expresión se presenta como:

$$u = P + I \frac{1}{s} + D \frac{N}{1 + N \frac{1}{s}} \quad (4.1)$$

donde P , I y D son las ganancias proporcional, integral y derivativa, respectivamente, y N es el coeficiente del filtro.

En la Tabla 4.6 se presentan los valores de las ganancias del PID ajustadas para la TG (planta a controlar).

Tabla 4.6
Ganancias del PID ajustadas para la TG.

Elemento	Valor de la ganancia
P	4.39927943085144
I	0.337972979021522
D	-1.39158020983219
N	0.271365320106683

Nota. Elaboración propia.

En la Figura 4.40 se muestra el diagrama de bloques del sistema de control en lazo cerrado con el controlador PID de la TG.

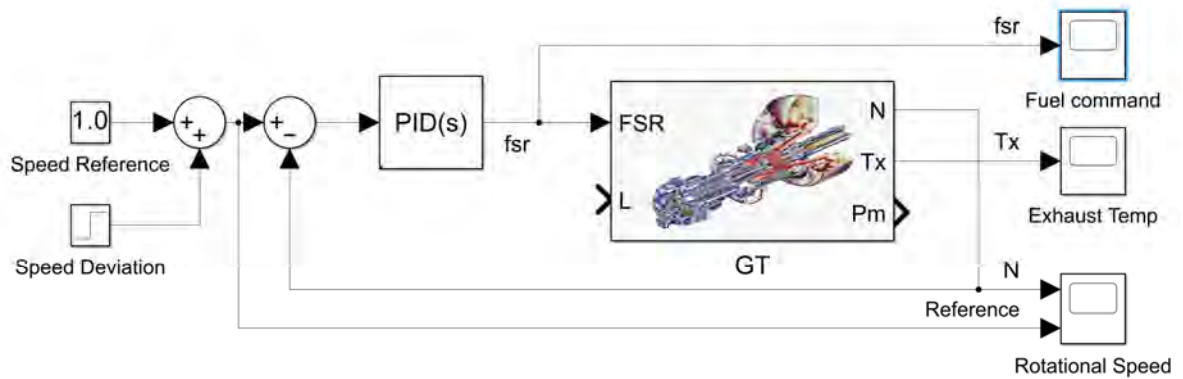


Figura 4.40. Diagrama del sistema de control en lazo cerrado de la TG con el controlador PID.

4.5.2 Simulación del sistema de control de la TG con controlador PID

Luego de completar el diseño, se puede ejecutar la simulación del sistema de control de lazo cerrado completo. Los resultados de la simulación se presentan en las Figuras 4.41 a 4.43.




Figura 4.41. Señal de control (FSR) del controlador PID.




Figura 4.42. Respuesta del sistema de control de la temperatura de escape de la TG con el controlador PID.




Figura 4.43. Respuesta del sistema de control de la velocidad de rotación de la TG con el controlador PID frente a una entrada escalón de velocidad de 0.05 p.u.

El desempeño obtenido por el sistema de control con el PID frente a la entrada escalón de velocidad se exhibe en la Tabla 4.7.

Tabla 4.7
Performance obtenida del sistema de control con el PID.

Condición	Valor
Tiempo de subida	4.89 s
Tiempo de establecimiento	32.53 s
Sobre impulso	10.35 %
Error de estado estacionario	0.00 %
Estabilidad en lazo cerrado	Estable

Nota. Elaboración propia.

Como se puede observar, el rendimiento del controlador cumple con los requisitos propuestos de diseño; sin embargo, es el controlador de menor rapidez y el que más sobre impulso presenta. No obstante, una característica positiva consiste en que logra que la variable a controlar no presente error de estado estacionario.

4.6 Comparación del performance de los controladores diseñados

La comparación del desempeño de los controladores diseñados se realizó en Simulink-MATLAB en un mismo entorno de simulación y con la misma entrada para cada sistema de control.

El diagrama de bloques del sistema de control de la turbina de gas implementado en Simulink-MATLAB se muestra en la Figura 4.44. En este diagrama se han incluido el controlador de velocidad original propuesto por Rowen (regulador de velocidad), que es equivalente a un sistema de primer orden, el controlador predictivo basado en RNA (RNA-MPC), el controlador de linealización por retroalimentación (NARMA-L2) y el controlador PID convencional. Los bloques GT1, GT2, GT3 y GT4 se refieren al mismo modelo de la TG presentado anteriormente.

Las especificaciones de amplitud de la referencia aleatoria (función escalón) son las mismas que fueron consideradas durante la etapa de diseño. Es decir, una variación en la consigna de la velocidad de rotación de la TG en el intervalo de -0.05 a +0.07 p.u.

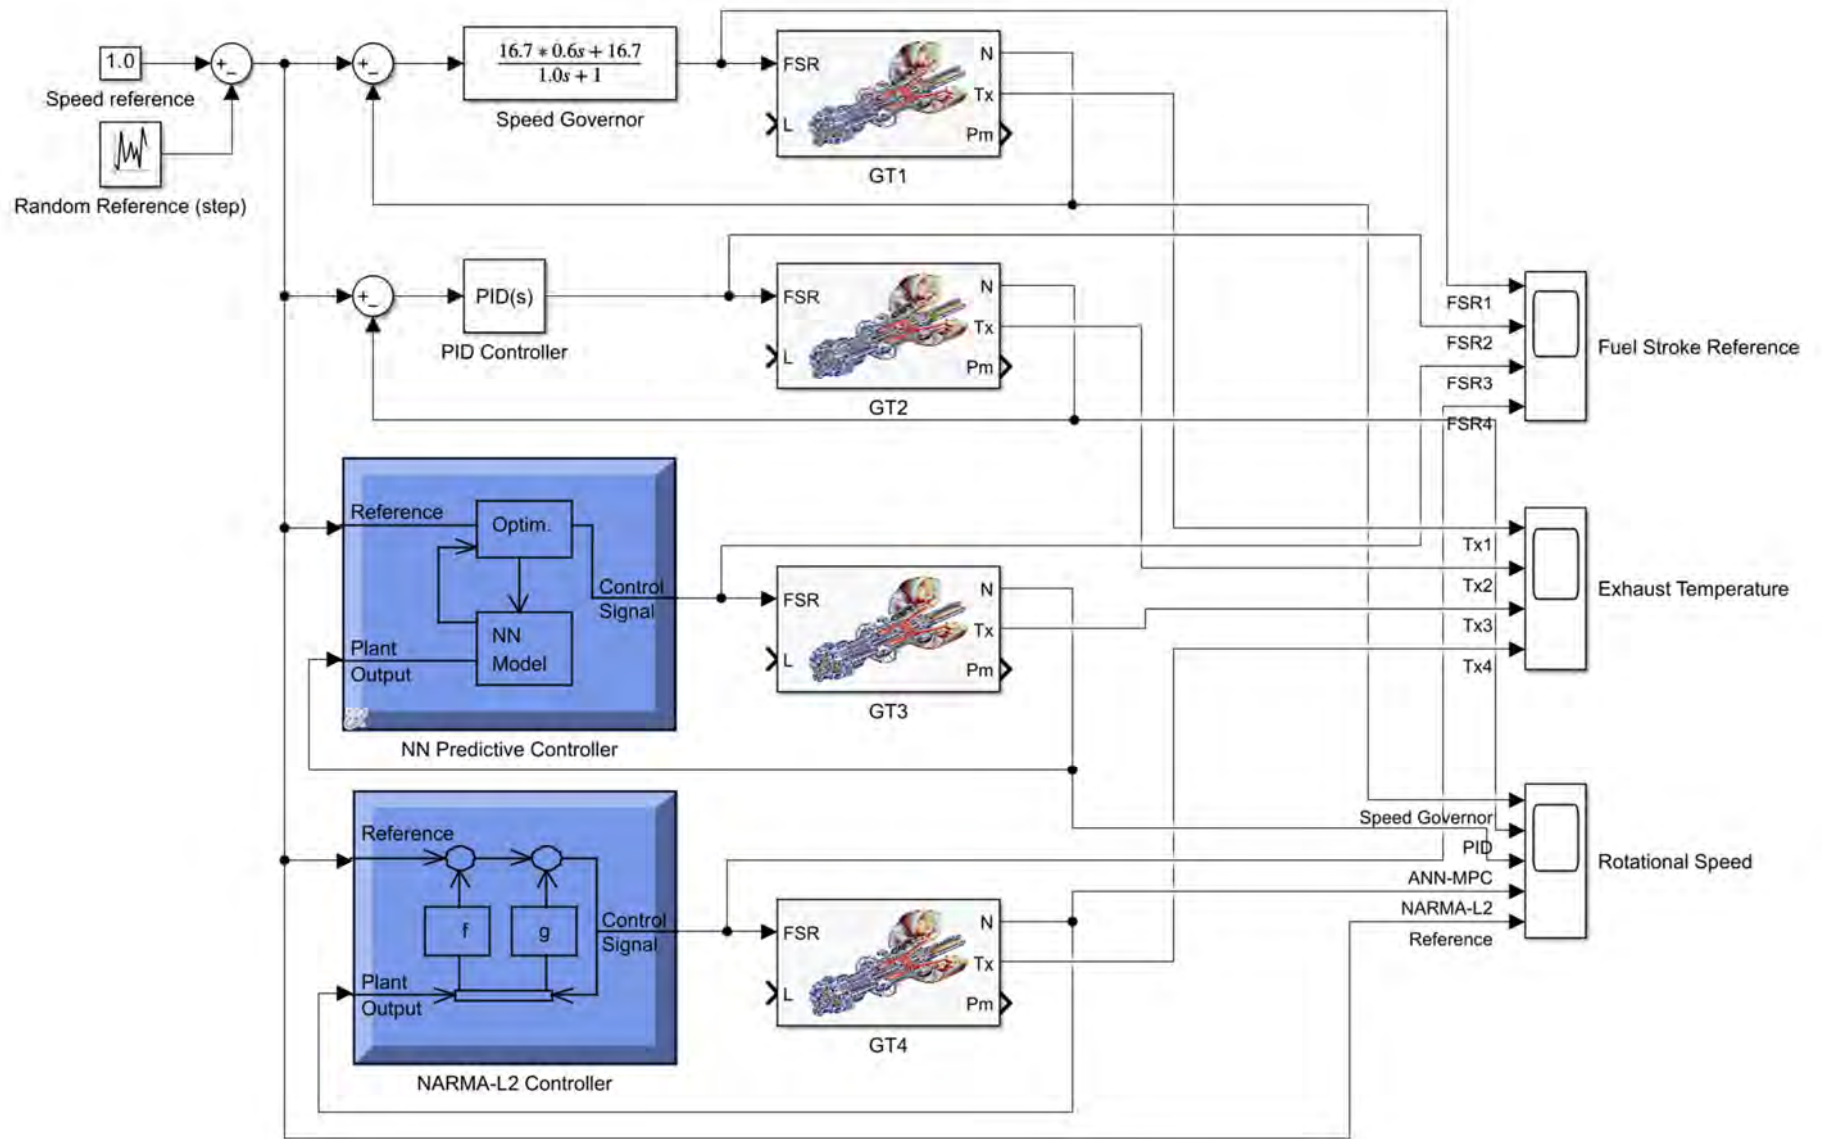


Figura 4.44. Diagrama de bloques en Simulink-MATLAB del sistema de control de la TG con controladores: Regulador de Velocidad, PID, RNA-MPC y NARMA-L2.

Dada la dinámica de la TG, se ejecutó la simulación durante 180 s, durante los cuales se pudo observar la respuesta completa de los cuatro controladores. En las Figuras 4.45 a 4.47 se muestran las performances obtenidas por cada uno de los cuatro controladores frente a una referencia de variación aleatoria de la velocidad de rotación.




Figura 4.45. Respuestas de los controladores diseñado frente a una señal de variación aleatoria de la velocidad de rotación de la TG.




Figura 4.46. Vista ampliada de las respuestas temporales del sistema de control con los controladores diseñados representadas en la figura 3.48.

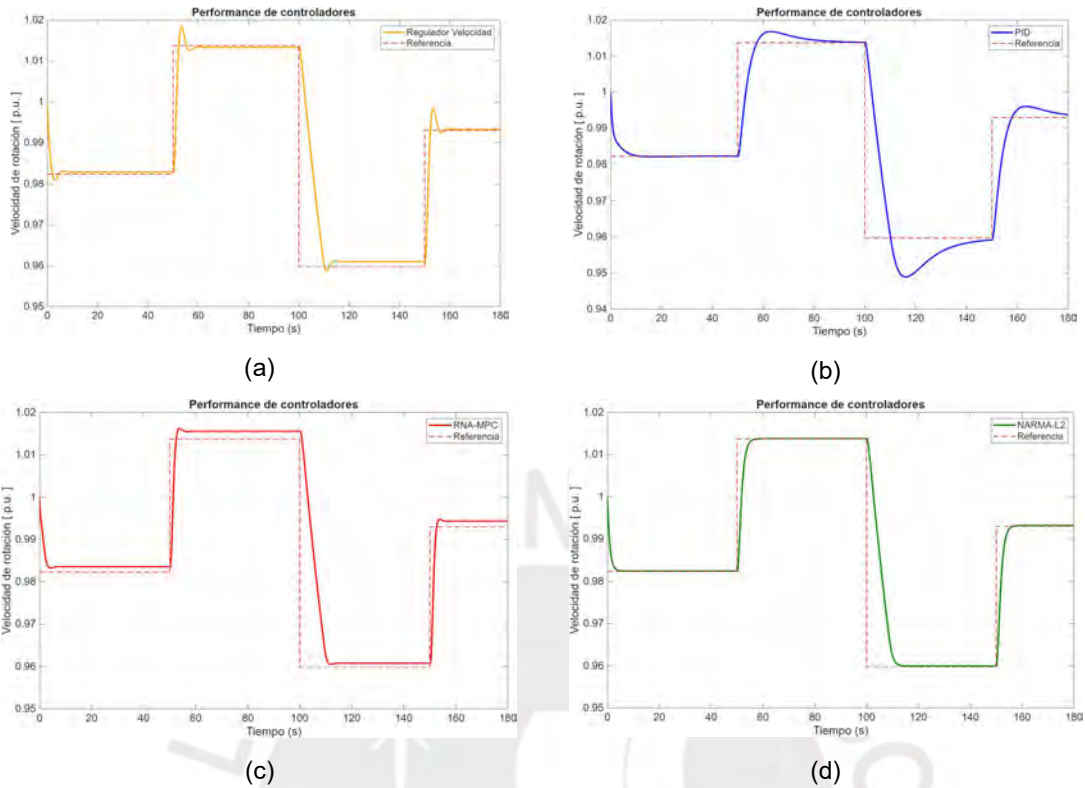


Figura 4.47. Performances de los controladores: (a) Regulator Velocidad, (b) PID, (c) RNA-MPC, (d) NARMA-L2.

En el sistema implementado, también es posible observar el comportamiento del sistema de control frente a una variación en la referencia de la carrera del combustible (FSR), que es el comando de posición de la válvula de combustible que regula el caudal másico del gas que ingresa a la cámara de combustión de la TG (Figura 4.48 y 4.49), y la temperatura de los gases de escape de la TG (Figura 4.50 y 4.51).

Como se puede observar los controladores diseñados cumplen con los objetivos propuestos, sin embargo, el controlador NARMA-L2 presenta un rendimiento superior a los otros controladores.

Se verifica que con el controlador NARMA-L2, la velocidad de rotación de la turbina de gas sigue a la referencia con rapidez y mayor precisión. El tiempo de establecimiento y el tiempo de subida son solo superados por el controlador RNA-MPC, pero a diferencia de este, la respuesta no presenta sobre impulso o error de

estado estacionario. También se infiere de estos resultados, que los controladores basados en RNA son más rápidos y efectivos que el PID.




Figura 4.48. Señales de control generadas por los controladores diseñados ante una variación en la referencia de velocidad.




Figura 4.49. Vista ampliada de las señales de control.




Figura 4.50. Respuestas del sistema de control de la temperatura de escape de la TG con los controladores diseñados.




Figura 4.51. Vista ampliada de las respuestas presentadas en la Figura 4.50.

Una observación interesante en este estudio es que las tendencias de la variable velocidad de rotación, mostradas en las figuras, evidencian que la respuesta del sistema en lazo cerrado de la turbina de gas (para todos los controladores) a una

entrada escalón comienza con un impulso negativo. Esto se debe a que la turbina de gas es un sistema de fase no mínima (NMP) [90].

En la Tabla 4.8 se presenta una tabla comparativa de los cuatro controladores: el regulador de velocidad propuesto por Rowen y los tres controladores diseñados. Se especifican sus características de respuesta en base a las simulaciones realizadas.

Tabla 4.8
Características de operación de los controladores diseñados RNA-MPC, NARMA-L2 y PID.

Condición	Regulador Velocidad	RNA-MPC	NARMA-L2	PID
Tiempo de subida	1.46 s	1.71 s	2.94 s	4.89 s
Tiempo de establecimiento	7.04 s	2.49 s	4.31 s	32.53 s
Sobre impulso	14.06 %	3.30 %	0.16 %	10.35 %
Error de estado estacionario	2.77 %	0.22 %	0.00 %	0.00 %
Estabilidad en lazo cerrado	Estable	Estable	Estable	Estable

Nota. Elaboración propia.

4.7 Conclusiones

Se desarrolló el diseño de controladores para el control de la velocidad de rotación, la cual es una de las variables críticas de la TG objeto de estudio. Se presentaron cuatro controladores diferentes, tres de ellos fueron diseñados cumpliendo los requisitos planteados y uno corresponde al controlador original propuesto por Rowen para el modelo de la TG seleccionada.

Los controladores diseñados son: el PID convencional, el controlador RNA-MPC, y el controlador NARMA-L2. Los fundamentos de estos controladores fueron descritos brevemente.

Para el caso de los controladores avanzados, se realizó el entrenamiento de los modelos basados en RNA dinámicas (NARX) a partir de datos de la planta y sus

parámetros fueron ajustados en el entorno Simulink-MATLAB de acuerdo con los objetivos de control señalados.

Finalmente, se exploraron y compararon los rendimientos de los controladores diseñados y del regulador de velocidad del modelo original propuesto por Rowen. Los resultados obtenidos mostraron que el controlador NARMA-L2 tiene una performance superior a los otros controladores.



Capítulo 5: Propuesta de implementación del controlador avanzado basado en RNA

En correspondencia con los resultados obtenidos de los controladores diseñados basados en RNA para el sistema de control de la TG detallados en el capítulo anterior, se destaca el controlador de linealización de retroalimentación (NARMA-L2) por su mejor desempeño. Así, en el presente capítulo se desarrolla una propuesta de implementación de este tipo de controlador en una TG de un solo eje y ciclo simple utilizada para la generación eléctrica.

5.1 Hardware del sistema

El sistema de control sobre el cual se propone implementar el controlador basado en RNA es el mismo correspondiente al turbogenerador Solar Centaur 50. Este sistema denominado por el fabricante como Turbotronic 4 se encarga del monitoreo y control de la turbo maquinaria y del generador eléctrico. La arquitectura del sistema está basada en el hardware de Rockwell Automation/Allen Bradley. Esta se expone en la Figura 5.1 y sus principales componentes son descritos en la Tabla 5.1.

Tabla 5.1
Componentes del sistema de control Turbotronic 4.

Componente	Marca
PLC ControlLogix	Allen Bradley
Módulos de entradas y salidas 1794 Flex IO	Allen Bradley
Módulo de control de generador	Allen Bradley
Sistema de monitoreo de vibraciones 1701 FiedMonitor	Bently Nevada
Red industrial ControlNet	Allen Bradley
Interfase de operación local TT4000S	Solar Turbines
Panel de operación local	Solar Turbines
Sistema de fuego y gas	Det-tronics
Sistema de respaldo de paro	Solar Turbines

Nota. Adaptador de [71].

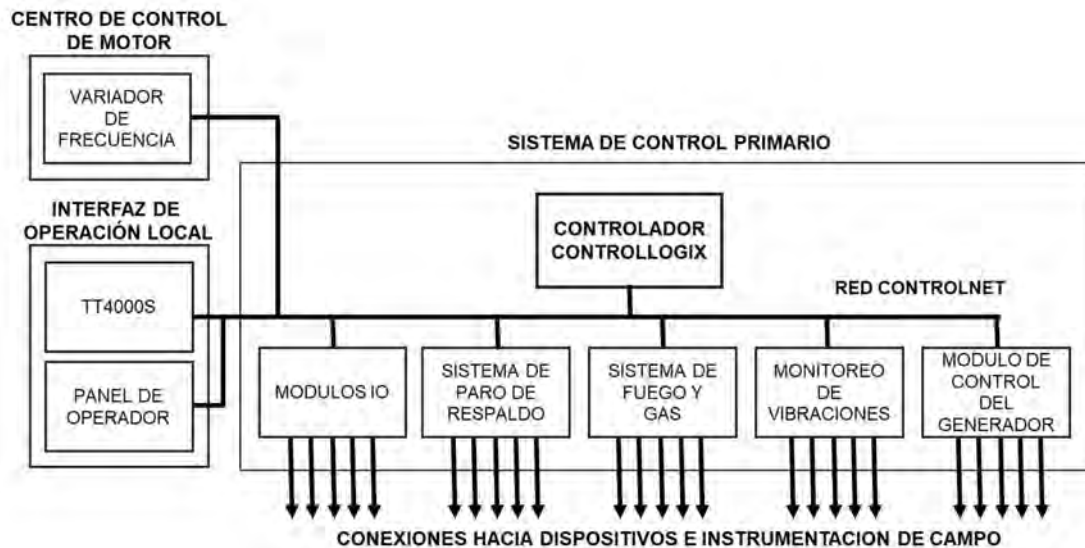


Figura 5.1. Arquitectura del sistema de control Turbotronic 4. Adaptado de [71].

5.2 Programación del controlador lógico programable

En el controlador lógico programable (PLC) ControlLogix, se ejecutan las rutinas y sentencias que proporcionan el control primario a la turbina de gas. Para su programación se utiliza el software RSLogix 5000, de Rockwell Automation, el cual soporta lenguajes de programación basados en el estándar IEC-61131-C, los cuales son: diagrama de contactos (LD), diagrama de bloques de funciones (FBD), diagrama de funciones secuenciales (SFC), y texto estructurado (ST). Este último, es un lenguaje de alto nivel que puede ser utilizado para poner en funcionamiento algoritmos matemáticos complicados. Por tanto, se propone implementar el controlador basado en RNA utilizando el lenguaje ST en combinación con LD.

Para crear las rutinas del programa del controlador, se ha considerado utilizar un método de generación de código, que elimina la codificación manual tradicional y reduce el tiempo necesario. Este se realiza mediante el uso del Toolbox Simulink PLC Coder de MATLAB. Esta herramienta permite convertir a lenguaje de texto estructurado los subsistemas desarrollados en Simulink con precisión y rapidez.

En la Figura 5.2 se exhibe el diagrama bloques del sistema de control de la velocidad de rotación de la TG considerando el controlador basado en RNA.

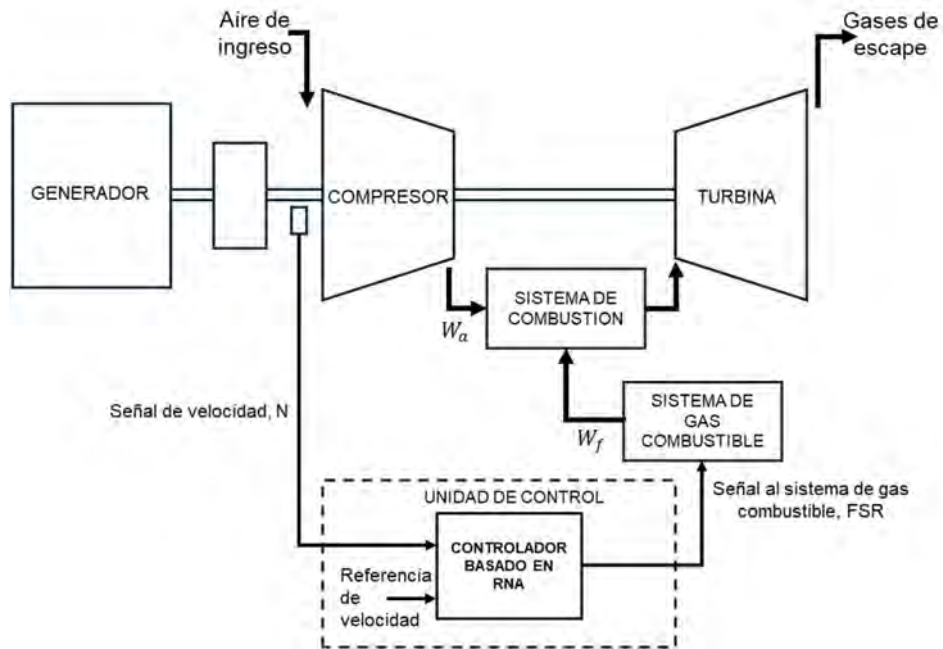


Figura 5.2. Diagrama de bloques del sistema de control de la velocidad de rotación de la TG con controlador basado en RNA.

En la Figura 5.3 se presenta el diagrama de bloques de la implementación propuesta para el sistema de control de la velocidad de rotación de la TG considerando el controlador de linealización por retroalimentación NARMA-L2 diseñado.

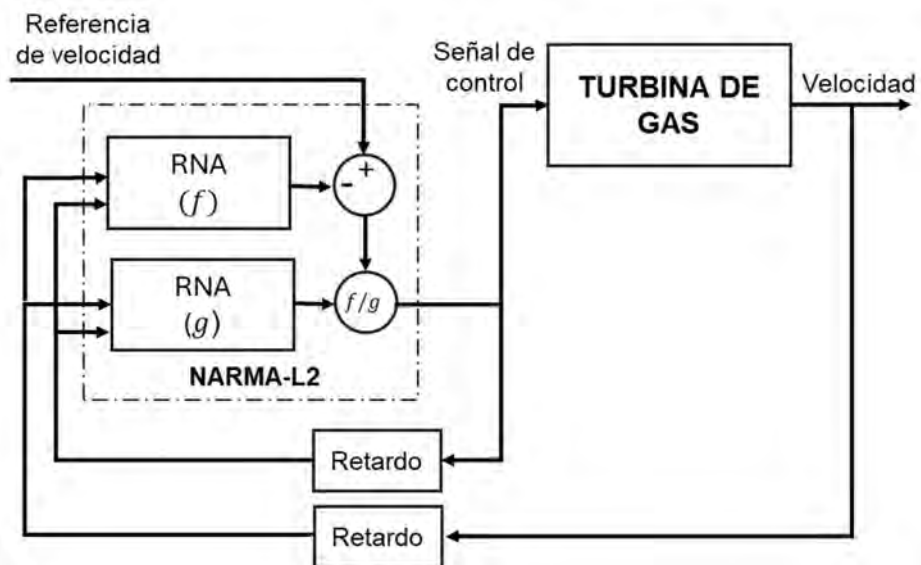


Figura 5.3. Diagrama de bloques simplificado del sistema de control de la velocidad de rotación de la TG con el controlador NARMA-L2.

5.3 Conclusiones

Se desarrolló una propuesta de implementación del sistema de control de la velocidad de rotación de la turbina de gas utilizando el controlador de linealización por retroalimentación NARMA-L2 diseñado.

Para crear las rutinas del programa del controlador se utilizó el Toolbox Simulink PLC Coder de MATLAB que permite convertir a lenguaje de texto estructurado los subsistemas desarrollados en Simulink con precisión y rapidez.



Conclusiones generales

Se desarrolló un estudio sobre el estado del arte de la identificación, el modelado, y el control de las TG, el cual es fundamental para el desarrollo de nuevos y efectivos sistemas de control, así como de nuevas investigaciones en este importante campo del conocimiento.

Se presentaron los principios básicos del marco teórico que se utiliza en el desarrollo de esta tesis, los cuales incluyen al controlador clásico PID, las RNA y su aplicación en el diseño de un controlador MPC basado en una RNA (RNA-MPC), y al controlador de linealización por retroalimentación (NARMA-L2).

Se realizó la identificación del comportamiento dinámico de una TG industrial de un solo eje utilizada para la generación eléctrica durante la fase de arranque y durante maniobras de demanda de potencia (variación de carga). Se construyeron modelos basados en RNA dinámicas NARX a partir de series de datos experimentales capturados durante la operación de la TG. Se validaron los resultados de los modelos para los valores de operación de velocidad de rotación y temperatura de salida de los gases de la TG en función de la temperatura de ingreso y el caudal másico del gas combustible. Se confirmó que los modelos NARX son capaces de capturar y predecir la dinámica de la TG durante la etapa de arranque y durante maniobras de demanda de potencia incluso con perturbaciones en la carga. Se demostró que en procesos donde no se tiene información suficiente para un modelado basado en ecuaciones físicas compleja los modelos NARX son válidos para el modelado considerando diferentes escenarios de operación.

Se desarrolló el diseño de diferentes controladores para el control de la velocidad de rotación de la TG objeto de estudio. Los controladores diseñados son: un controlador RNA-MPC, un controlador NARMA-L2, y un PID convencional. Para evaluar los resultados del desempeño de los controladores, se ejecutaron simulaciones utilizando el entorno Simulink-MATLAB con la misma entrada para los sistemas de control. Los resultados revelaron que el controlador NARMA-L2 presenta un rendimiento superior en comparación con los controladores RNA-MPC y PID, tanto en términos de

velocidad de respuesta, como de tiempo de establecimiento, incluso sigue a la referencia de manera más precisa que los otros dos controladores.

Finalmente, se desarrolló una propuesta de implementación del controlador NARMA-L2 sobre una plataforma real que controla y monitorea una TG de ciclo simple utilizando el Toolbox Simulink PLC Coder de MATLAB, el cual posibilita convertir a lenguaje de texto estructurado los subsistemas desarrollados en Simulink con precisión y rapidez.

Recomendaciones

El presente trabajo de investigación pretende ser considerado como un aporte al campo del modelado y control de las TG. Si bien existen diferentes tipos de TG, se puede afirmar que los principios físicos de su funcionamiento son los mismos, por lo que las técnicas presentadas son perfectamente aplicables a un amplio rango de las turbomáquinas. Como se mencionó anteriormente, se trata de un campo de estudio que aun presenta retos y oportunidades, en especial en el ámbito actual, donde se vive una etapa de transición hacia el uso de fuentes de energía más sostenibles y donde estos sistemas son cada vez más utilizados.

Con respecto al modelado y la simulación, se puede utilizar la misma metodología para investigar:

- El comportamiento dinámico de las TG de un solo eje que sean utilizadas como accionamientos mecánicos de otros equipos, como son los turbocompresores que han sido instalados de manera extensa en diversas plantas industriales. Se trata de máquinas de mayor complejidad, con un rango de variación de velocidad mayor, y donde debe incluirse en el modelo el flujo de aire hacia el sistema de combustión regulado por la apertura y cierre de la IGV en condiciones de operación que no sean de carga completa.
- El comportamiento dinámico de las TG de doble eje, utilizadas tanto para la generación eléctrica, como en los accionamientos mecánicos, debido a que tienen mayor flexibilidad en el manejo de cargas en estados transitorios.
- El uso de modelos basados en RNA con otras arquitecturas para modelar TG y compararlas con los resultados obtenidos con la arquitectura NARX.
- La identificación y modelado de unidades completas que integren TG, como trenes de compresión, que permitan ajustar los modelos de una planta para una mejor operación y regulación.

Sobre los sistemas de control de TG propiamente, se pueden realizar estudios para profundizar en:

- El diseño de controladores multivariables que permitan controlar la velocidad de rotación, la aceleración y la temperatura de los gases de escape de manera simultánea.
- El empleo de controladores basados en RNA para TG de doble eje, utilizadas tanto en la generación eléctrica, como en los accionamientos mecánicos, y en diferentes estados de operación (durante el arranque y demanda de potencia).
- El diseño y empleo de controladores autoajustables y flexibles para TG de múltiples configuraciones.
- El diseño de controladores H_{∞} aplicados a TG que permitan garantizar un rendimiento superior para diferentes condiciones operativas y perturbaciones de la planta.

Se considera que para el diseño de controladores basados en RNA de TG, los resultados obtenidos en el presente estudio, así como las pruebas de simulación efectuadas contribuyen y representan una sólida base para una futura implementación de sistemas de control de TG reales.



Referencias Bibliográficas

- [1] Ceplan, PEDN Perú 2050 (2024). Plan estratégico de desarrollo nacional. *PEDN Perú 2050*, <https://peru2050.ceplan.gob.pe/>
- [2] Gürsan C., and De Gooyert V. (2025). The systemic impact of a transition fuel: does natural gas help or hinder the energy transition? *Renewable and Sustainable Energy Reviews*, 138, 110552. DOI: 10.1016/j.rser.2020.110552.
- [3] Colina-Calvo A. (2024). Una revisión integral del escenario energético del Perú: avanzando en el acceso a la energía, la sostenibilidad y las implicaciones políticas. *Revista Kawsaypacha: Sociedad y Medio Ambiente*, 14, D-006. DOI: 10.18800/kawsaypacha.202402.D006.
- [4] Ministerio de Energía y Minas de Perú (2022). Balance nacional de energía 2022. *Dirección General de Eficiencia Energética, Área de Planeamiento Estratégico*, 2023.
- [5] Zhou H., Xue J., Gao H., and Ma N. (2024). Hydrogen-fueled gas turbines in future energy system. *International Journal of Hydrogen Energy*, 64, 569–582. DOI: 10.1016/j.ijhydene.2024.03.327.
- [6] Patel S., and Vernova Unveils G. E. (2024). 100% hydrogen-fueled aeroderivative gas turbine solution, secures first customer. *POWER Magazine*, <https://www.powermag.com/ge-vernova-unveils-100-hydrogen-fueled-aeroderivative-gas-turbine-solution-secures-first-customer/>
- [7] Siemens Energy, SGT-A35.
<https://www.siemens-energy.com/global/en/home/products-services/product/sgt-a30-a35-rb.html#/>
- [8] Turbine (2025). Merriam-webster dictionary. Disponible: <https://www.merriam-webster.com/dictionary/turbine>
- [9] Boyce M. P. (2006). *Gas turbine engineering handbook*. DOI: 10.1016/b978-0-7506-7846-9.x5000-7.
- [10] Baskharone E. A. (2006). Introduction to gas-turbine engines. *In Principles of Turbomachinery in Air-Breathing Engines* (1–8), chapter, Cambridge: Cambridge University Press.
- [11] Gas Turbines (2016). *Understanding CHP.com*.
<https://understandingchp.com/chp-applications-guide/4-3-gas-turbines/>
- [12] Santiago R. (2024). Brayton cycle for gas turbines. *Discover Engineering*. <https://www.discoverengineering.org/brayton-cycle-for-gas-turbines/>.
- [13] Mohamed O., and Khalil A. (2020). Progress in modeling and control of gas turbine power generation systems: a survey. *Energies*, 13(9), 2358. DOI:

10.3390/en13092358.

- [14] Aquize R., Cahuaringa A., Machuca J., Mauricio D., and Villanueva J. M. M. (2023). System identification methodology of a gas turbine based on artificial recurrent neural networks. *Sensors*, 23(4), 2231. DOI: 10.3390/s23042231.
- [15] Rivas-Perez R. (1991). Synthesis of optimal stationary automatic control systems of water distribution in main irrigation canal by means of time delay compensation. *Land Reclamation and Water Management*, 74, 77-82.
- [16] Bielski P., Eismont A., Bach J., Leiser F., Kottonau D., and Böhm K. (2024). *Knowledge-guided learning of temporal dynamics and its application to gas turbines*. New York, United States of America: Association for Computing Machinery, 279–290. DOI: 10.1145/3632775.3661967.
- [17] Rowen W. I. (1983). Simplified mathematical representations of heavy-duty gas turbines. *Journal of Engineering for Power*, 105(4), 865–869. DOI: 10.1115/1.3227494.
- [18] Rowen W. I. (1992). Simplified mathematical representations of single shaft gas turbines in mechanical drive service, Vol. 5. *Manufacturing Materials and Metallurgy, Ceramics, Structures, and Dynamics, Controls, Diagnostics and Instrumentation. Education*. DOI: 10.1115/92-gt-022.
- [19] De Mello F. P., and Ahner D. J. Dynamic models for combined cycle plants in power system studies. *IEEE Transactions on Power Systems*, 9(3), 1698–1708. DOI: 10.1109/59.336085.
- [20] CIGRE Task Force C4.02.25 (2003). Modeling of gas turbines and steam turbines in combined cycle power plants. CIGRE Technical Brochure 238.
- [21] Sun L., Liu T., Xie Y., Zhang D., and Xia X. (2021). Real-time power prediction approach for turbine using deep learning techniques. *Energy*, 233, 121130. DOI: 10.1016/j.energy.2021.121130.
- [22] Asgari H. (2014). Modelling, simulation and control of gas turbines using artificial neural networks. Ph.D. Thesis of Philosophy in Mechanical Engineering, University of Canterbury Christchurch, New Zealand. DOI: 10.26021/3555.
- [23] Asgari H., and Chen X. (2015). Gas turbines modeling, simulation, and control. DOI: 10.1201/b18956.
- [24] Asgari H., Chen X., Menhaj M. B., and Sainudiin R. (2013). Artificial neural network-based system identification for a single-shaft gas turbine. *Journal of Engineering for Gas Turbines and Power*, 135(9). DOI: 10.1115/1.4024735.
- [25] Asgari H., Chen X. Q., Menhaj M. B., and Sainudiin R. (2012). ANN-based system identification, modelling and control of gas turbines – a review. *Advanced Materials Research*, 622–623, 611–617. DOI: 10.4028/www.scientific.net/amr.622-623.611.

- [26] Singh R., Maity A., and Nataraj P. S. V. (2019). Shaft speed control of laboratory gas turbine engine. *IFAC-PapersOnLine*, 52(12), 262–267. DOI: 10.1016/j.ifacol.2019.11.253.
- [27] Zhang F., Xue Y., Wei B., and Zhang B. (2022). Model predictive control for gas turbine shaft speed based on model compensation using extended state observer. *Proceedings of the Institution of Mechanical Engineers Part I Journal of Systems and Control Engineering*, 237(3), 513–523. DOI: 10.1177/09596518221127511.
- [28] Hadroug N., Hafaifa A., Guemana M., Kouzou A., Salam A., and Chaibet A. (2017). Heavy duty gas turbine monitoring based on adaptive neuro-fuzzy inference system: speed and exhaust temperature control. *Mathematics-in-Industry Case Studies*, 8(1). DOI: 10.1186/s40929-017-0017-8.
- [29] Hadroug N., Hafaifa A., Kouzou A., and Chaibet A. (2017). Improvement of gas turbine availability using reliability modeling based on fuzzy system. In *Applied Condition Monitoring*, 15–28. DOI: 10.1007/978-3-319-62042-8_2.
- [30] Cao Y., Wang J., Dai Y., and Xie D. (2015). study of the speed control system of a heavy-duty gas turbine. *Proceedings of the ASME Turbo Expo 2015: Turbine Technical Conference and Exposition. Volume 6: Ceramics, Controls, Diagnostics and Instrumentation, Education, Manufacturing Materials and Metallurgy, Honors and Awards*, V006T05A014 ASME. DOI:10.1115/GT2015-42887.
- [31] Najimi E., and Ramezani M. H. (2011). Robust control of speed and temperature in a power plant gas turbine. *ISA Transactions*, 51(2), 304–308, DOI: 10.1016/j.isatra.2011.10.001.
- [32] Lee Y. H., and So M. O. (2015). Speed control of marine gas turbine engine using nonlinear PID controller. *Journal of Navigation and Port Research*, 39(6), 457–463. DOI: 10.5394/kinpr.2015.39.6.457.
- [33] Mansourabad A., Beheshti M., and Simab M. (2013). A hybrid PSO_Fuzzy_PID controller for gas turbine speed control. *International Journal of Control and Automation*, 6, 13-24.
- [34] Hashmi M. B., Mansouri M., and Assadi M. (2023). Dynamic performance and control strategies of micro gas turbines: state-of-the-art review, methods, and technologies. *Energy Conversion and Management X*, 18, 100376. DOI: 10.1016/j.ecmx.2023.100376.
- [35] Saadat B., Kouzou A., Guemana M., and Hafaifa A. (2017). Gas turbine speed and axial load control using fuzzy system: Exhaust temperature supervision. *3rd International Conference on Mechanics*.
- [36] Rivas-Perez R., and Sotomayor-Moriano J. (2014). Control predictivo generalizado de las variables críticas de una unidad de ósmosis inversa. *Memorias del XVI Congreso Latinoamericano de Control Automático*, 642-647.

- [37] Salcedo J., Rivas R., and Sotomayor J. J. (2018). Design of a generalized predictive controller for temperature control in a cement rotary kiln. *IEEE Latin America Transactions*, 16(4), 1015-1021.
- [38] Rivas-Perez R., Sotomayor Moriano J., and Perez-Zuñiga C. G. (2017). Adaptive expert generalized predictive multivariable control of seawater RO desalination plant for a mineral processing facility. *IFAC-PapersOnLine*, 50(1), 10244-10249.
- [39] Guo S., He A., Xiao B., Liu P., and Wang Z. (2022). A novel integrated control method for an aero-derivative gas turbine of power generation. *Machines*, 10(3), 179. DOI: 10.3390/machines10030179.
- [40] Paoli N. (2009). Simulation models for analysis and optimization of gas turbine cycles. M.S Thesis in Chemical Engineering, Pisa University, Italy. <https://core.ac.uk/download/pdf/14697348.pdf>
- [41] Tavakoli M. R. B., Vahidi B., and Gawlik W. (2009). An educational guide to extract the parameters of heavy-duty gas turbines model in dynamic studies based on operational data. *IEEE Trans. on Power Systems*, 24(3), 885-895.
- [42] Sanchez-Rodriguez L., Feliu-Batlle V., Rivas-Perez R., and Ruiz Torija M. A. (2007). Robust control of a laboratory hydraulic canal by using a fractional PI controller. *Proceedings of the ASME 2007 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, 5, A, B and C, paper No DETC2007-34670, 1307-1315.
- [43] Feliu-Batlle V., and Rivas-Perez R. (2019). Smith predictor based fractional-order integral controller for robust temperature control in a steel slab reheating furnace. *Transactions of the Institute of Measurement and Control*, 41(16), 4521-4534.
- [44] Suarez A. M., Duarte-Mermoud M. A. and Bassi D. F. (2006). A predictive control scheme based on neural networks. *Kybernetes*, 35(10), 1579-1606.
- [45] Kovalenko P. I., Matzeliuk E. M., and Rivas-Perez R. (1990). Adaptive control of water distribution in main irrigation canals with variable time delay. *Scientific Researches in Hydrotechnique and Land Reclamation*, 32-40.
- [46] Araki M. (1984). PID control. In *Control, Systems, Robotics, and Automation*, vol. 2.
- [47] Bansal H. (2009). Tuning of PID controllers using Simulink. *International Journal of Mathematical Modeling, Simulation and Applications*.
- [48] Feliu Batlle V., Rivas-Perez R., and Castillo F. (2005). Fractional robust control to delay changes in main irrigation canals. *IFAC Proceedings Volumes*, 38(1), 28-33.
- [49] Sanchez-Rodriguez L., Feliu-Batlle V., Rivas-Perez R., and Ruiz Torija M. A. (2007). Robust control of a laboratory hydraulic canal by using a fractional PI controller. *Proceedings of the ASME 2007 International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, 5, A, B and C, paper No DETC2007-34670, 1307-1315.

- [50] Feliu-Batlle V., and Rivas-Perez R. (2019). Smith predictor based fractional-order integral controller for robust temperature control in a steel slab reheating furnace. *Transactions of the Institute of Measurement and Control*, 41(16), 4521-4534.
- [51] Castillo-Garcia F. J., Feliu-Batlle V., Rivas-Perez R., and Sanchez-Rodriguez L. (2011). Time domain tuning of a fractional order PI λ controller combined with a Smith predictor for automation of water distribution in irrigation main channel pools. *IFAC Proceedings Volumes*, 44(1), 15049-15054.
- [52] McCulloch W., and Pitts W. (2021). A logical calculus of ideas immanent in nervous activity (1943). In *The MIT Press eBooks*, 79–88. DOI: 10.7551/mitpress/12274.003.0011.
- [53] Qamar R., and Zardari B. A. (2023). Artificial neural networks: an overview. *Mesopotamian Journal of Computer Science*, 130–139. DOI: 10.58496/mjcs/2023/015.
- [54] Bre F., Gimenez J. M., and Fachinotti V. D. (2017). Prediction of wind pressure coefficients on building surfaces using artificial neural networks. *Energy and Buildings*, 158, 1429–1441. DOI: 10.1016/j.enbuild.2017.11.045.
- [55] Hancock J. T., and Khoshgoftaar T. M. (2020). Survey on categorical data for neural networks. *Journal of Big Data*, 1, 1-41.
- [56] Ibrahim I. M. A., Akhrif O., Moustapha H., and Staniszewski M. (2021). Nonlinear generalized predictive controller based on ensemble of NARX models for industrial gas turbine engine. *Energy*, 230, 120700. DOI: 10.1016/j.energy.2021.120700.
- [57] Hudson M., Hagan M., and Demuth H. (2020). *Deep Learning Toolbox™ User's Guide*. The MathWorks, Inc.
- [58] Qin S. J., and Badgwell T. A. (1997). An overview of industrial model predictive control technology. In J. Kantor, C. Garcia and B. Carnahan (eds.), *Chemical Process Control - AIChE Symposium Series*, 232-256.
- [59] Seborg D. E. (1999). A perspective on advanced strategies for process control (revisited). In *Springer eBooks*, 103–134. DOI: 10.1007/978-1-4471-0853-5_4.
- [60] Qin S. J., and Badgwell T. A. (1998). An overview of nonlinear model predictive control applications". *IFAC Workshop on Nonlinear Model Predictive Control – Assessment and Future Directions*, Ascona, Switzerland.
- [61] Meadow E. S., and Rawlings J. B. (1997). Model predictive control. In M. Hesnon and D. Seborg (eds.), *Nonlinear Model Predictive Control*, 233-310. NJ: Prentice Hall.
- [62] Soloway D., and Haley P. J. (1996). Neural generalized predictive control. *Proceedings of the 1996 IEEE International Symposium on Intelligent Control*, 277–281.

- [63] Hagan M.T., and Demuth H.B. (1999). Neural networks for control. Proceedings of the 1999 American Control Conference, 1642–1656.
- [64] Narendra K. S., and Parthasarathy K. (1991). Learning automata approach to hierarchical multiobjective analysis. *IEEE Transactions on Systems Man and Cybernetics*, 21(1), 263–272, DOI: 10.1109/21.101158.
- [65] Narendra K. S., and Mukhopadhyay S. (1997). Adaptive control using neural networks and approximate models. *IEEE Transactions on Neural Networks*, 8(3), 475–485. DOI: 10.1109/72.572089.
- [66] Dash S. (2020). Load frequency control of solar pv and solar thermal integrated micro grid using Narma-L2 controller. *ArXiv (Cornell University)*, DOI: 10.48550/arxiv.2004.05776.
- [67] Rivas-Perez R., Feliu-Batlle V., Castillo-Garcia F. J., Sanchez-Rodriguez L., and A. Linares-Saez A. (2011). Control-oriented model of a complex irrigation main canal pool. *IFAC Proceedings Volumes*, 44(1), 2919-2924.
- [68] Benitez I.O., Rivas R., Feliu V, Sanchez L. P., and Sanchez L. A. (2016). Fuzzy gain scheduled Smith predictor for temperature control in an industrial steel slab reheating furnace. *IEEE Latin America Transactions*, 14(11), 4439-4444.
- [69] Kao T. G., Nguen M., and Rivas-Perez R. (1988). Adaptive control of a delay plant by using a nonsearching self-adjusting systems with a model. *Avtomatika i Telemekhanika*, 12, 106-116.
- [70] Castillo-Garcia F., Rivas-Perez R., and Feliu-Batlle V. (2008). Fractional I_q controller combined with a Smith predictor for effective water distribution in a main irrigation canal pool. *IFAC Proceedings Volumes*, 41(2), 14558-14563.
- [71] Solar Turbines Incorporated, CENTAUR 50 (2009). Turbomachinery Package Specification. Generator.
- [72] Paiva C. (2018). Gas turbines: modelling for stability studies. Lisbon Higher Technical Institute.
- [73] Chai T., and Draxler R. (2014). Root mean square error (RMSE) or mean absolute error (MAE). *Geosci*, 7. DOI: 10.5194/gmdd-7-1525-2014.
- [74] Bettocchi R., Pinelli M., Spina P., and Venturini M. (2007). Artificial intelligence for the diagnostics of gas turbines - Part i: neural network approach. *ASME Journal of Engineering for Gas Turbines and Power*, 129(3), 711-719.
- [75] Oglah A. A. and Mohammed A. J. (2018). Design of an interval fuzzy type-2- PID controller for a gas turbine power plant. *American Scientific Research Journal for Engineering, Technology, and Sciences*, 44(1), 155–169.
- [76] Shi G., Wu Z., He T., Li D., Ding Y., and Liu S. (2020). “Shaft speed control of the gas turbine based on active disturbance rejection control. *IFAC-PapersOnLine*, 53(2), 12523–12529. DOI: 10.1016/j.ifacol.2020.12.1795.

- [77] Dorf R.C. and Bishop R.H. (2011). *Modern Control System*. Twelfth Edition, Pearson Education, Inc., NJ, USA.
- [78] Cvejn J. (2011). Simple PI/PID controller tuning rules for FOPDT plants with guaranteed closed-loop stability margin. *Acta Montanistica Slovaca*, 16, 17-25.
- [79] Kim P. (2017). *MATLAB deep learning: with machine learning, neural networks and artificial intelligence*. Seoul, Korea. DOI: 10.1007/978-1-4842-2845-6.
- [80] Paluszek M., Thomas S., and Ham E. (2022). *Practical MATLAB deep learning: a projects-based approach*, 2nd ed., 25-41, Apress.
- [81] Duvanov E. S., Pashchenko A. F., Batishchev R. V., Kharitonenko P. P., and Szykh P. A. (2022). Designing a neural network-based predictive controller in MATLAB Simulink. 2022 4th International Conference on Control Systems, Mathematical Modeling, Automation and Energy Efficiency (SUMMA), 669–671. DOI: 10.1109/summa60232.2023.10349561.
- [82] Hornik K., Stinchcombe M., and White H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359–366. DOI: 10.1016/0893-6080(89)90020-8.
- [83] Bahar A., Özgen C., Leblebicioğlu K., and Halıcı U. (2004). “Artificial neural network estimator design for the inferential model predictive control of an industrial distillation column. *Industrial & Engineering Chemistry Research*, 43(19), 6102–6111. DOI: 10.1021/ie030585g.
- [84] Fan F.-L., Xiong J., Li, M., and Wang G. (2021). On interpretability of artificial neural networks: a survey. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 5(6), 741–760. DOI: 10.1109/trpms.2021.3066428.
- [85] Manonmani A., Thyagarajan T., Elango M., and Sutha S. (2016). Modelling and control of greenhouse system using neural networks. *Transactions of the Institute of Measurement and Control*, 40(3), 918–929. DOI: 10.1177/0142331216670235.
- [86] Garriga J. L., and Soroush M. (2010). Model predictive control tuning methods: a review. *Industrial & Engineering Chemistry Research*, 49(8), 3505–3515, DOI: 10.1021/ie900323c.
- [87] Moumouh H., Langlois N., and Haddad M. (2019). A novel tuning approach for MPC parameters based on artificial neural network. 2019 IEEE 15th International Conference on Control and Automation (ICCA), Edinburgh, UK, 1638-1643, DOI: 10.1109/ICCA.2019.8900026.
- [88] Alhajeri M., and Soroush M. (2020). Tuning guidelines for model-predictive control. *Industrial & Engineering Chemistry Research*, 59(10), 4177–4191, DOI: 10.1021/acs.iecr.9b05931.
- [89] Dennis, J.E., and R.B. Schnabel (1983). *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*, Englewood Cliffs, NJ, Prentice-Hall.

- [90] Hoagg J. B., and Bernstein D. S. (2007). Nonminimum-phase zeros - much to do about nothing - classical control - revisited part II. *IEEE Control Systems Magazine*, 27(3), 45–57, DOI: 10.1109/MCS.2007.365003.
- [91] Rivas-Perez R., Castillo-Garcia F., Sotomayor-Moriano J., and Feliu-Batlle V. (2014). Design of a fractional order PI controller for steam pressure in the steam drum of a bagasse fired boiler. *IFAC Proceedings Volumes*, 47(3), 1337–1342.
- [92] Feliu-Batlle V., Rivas-Perez R, and Castillo-Garcia F. (2021). Design of a PI α controller for the robust control of the steam pressure in the steam drum of a bagasse-fired boiler. *IEEE Access* 9, 95123–95134.
- [93] Rojas Carbajal D. E. (2016). Diseño de controladores PID avanzado para el control robusto de una unidad de ósmosis inversa de una planta desalinizadora de agua de mar. Tesis en opción al grado de magister en Ingeniería de Control y Automatización, PUCP, Lima, Perú.
- [94] Rivas-Perez R, Aref Ghraizi R, Cesar Sánchez E. (2000). Sistema de control automático integral de generadores de vapor pirotubulares. *Revista de Ingeniería Electrónica, Automática y Comunicaciones* 21(2), 10–18.
- [95] Åström K. J. and Hägglund T. (2009). *Control PID Avanzado*. Pearson Educación S.A., Madrid, España.
- [96] Feliu Batlle V., Sanchez Rodriguez L., Rivas Perez R., Pedregal Tercero D., et al. (2009). Fractional PI control of an irrigation main canal. *IFAC Proceedings Volumes* 40(1), 280–285.
- [97] Camacho E. F., and Bordons C. (1999). *Model Predictive Control*. Springer, Berlin, Germany.
- [98] Rivas-Perez R., y Sotomayor-Moriano J. (2014). Control predictivo generalizado de las variables críticas de una unidad de ósmosis inversa. *Memorias del XVI Congreso Latinoamericano de Control Automático*, 642-647.
- [99] Hernandez-Lopez Y., Rivas-Perez R., and Feliu-Batlle V. (2022). Design of a NARX-ANN-based SP controller for control of an irrigation main canal pool. *Applied Sciences* 12(18), 9180.
- [100] Benftima S., Gharab S., Rivas-Perez R., and Feliu-Batlle V. (2024). Modeling of an irrigation main canal pool based on a NARX-ANN system identification. *Communications in Nonlinear Science and Numerical Simulation* 132(107929).

Anexos

A. Códigos elaborados en MATLAB

A.1. Script para calcular y mostrar el mapa de calor de correlación de Pearson de las variables significativas de la turbina de gas

```
clc; clear; close all;

% Load database
f=readmatrix('Solar.xlsx');

T1 = f(:,3); % Inlet Temperature
mf = f(:,4); % Gas flow

Ngp = f(:,5); % Rotational Speed
T5 = f(:,6); % Exhaust Temperature

% Separate features and target
X = [mf T1];
Y = [Ngp T5];

% Combine features and target for correlation
data_all = [X Y];

% Compute Pearson correlation matrix
corr_matrix = corr(data_all);

% Create labels for axes
%labels = [compose('x%d', 1:size(X,2)), compose('Y%d', 1:size(Y,2))];
labels = [{'mf'}, {'T1'}, {'Ngp'}, {'T5'}];

% Create heatmap
figure;
h = heatmap(labels, labels, corr_matrix, ...
            'Colormap', jet, ...
            'ColorLimits', [-1 1]);

% Set global font size for heatmap (axes labels and cell values)
h.FontSize = 24;

% Add title using a separate uicontrol text object
RNAotation('textbox', [0.32, 0.92, 0.4, 0.05], ...
           'String', 'Pearson Correlation Heatmap', ...
           'FontSize', 24, ...
           'FontWeight', 'bold', ...
           'EdgeColor', 'none', ...
           'HorizontalAlignment', 'center');

% Resize figure to full screen
screenSize = get(0, 'ScreenSize');
set(gcf, 'Position', [1, 1, screenSize(3), screenSize(4)]);
```

A.2. Script para calcular y mostrar el mapa de calor de correlación de Spearman de las variables significativas de la turbina de gas.

```
clc; clear; close all;

% Load database
f=readmatrix('Solar.xlsx');

T1 = f(:,3); % Inlet Temperature
mf = f(:,4); % Gas flow

Ngp = f(:,5); % Rotational Speed
T5 = f(:,6); % Exhaust Temperature

% Separate features and target
X = [mf T1];
Y = [Ngp T5];

% Combine features and target for correlation
data_all = [X Y];

% Compute Pearson correlation matrix
corr_matrix = corr(data_all,"Type","Spearman");

% Create labels for axes
%labels = [compose('x%d', 1:size(X,2)), compose('y%d', 1:size(Y,2))];
labels = [{'mf'},{'T1'},{'Ngp'},{'T5'}];

% Create heatmap
figure;
h = heatmap(labels, labels, corr_matrix, ...
            'Colormap', jet, ...
            'ColorLimits', [-1 1]);

% Set global font size for heatmap (axes labels and cell values)
h.FontSize = 24;

% Add title using a separate uicontrol text object
RNAotation('textbox', [0.32, 0.92, 0.4, 0.05], ...
           'String', 'Spearman Correlation Heatmap', ...
           'FontSize', 24, ...
           'FontWeight', 'bold', ...
           'EdgeColor', 'none', ...
           'HorizontalAlignment', 'center');

% Resize figure to full screen
screenSize = get(0, 'ScreenSize');
set(gcf, 'Position', [1, 1, screenSize(3), screenSize(4)]);
```

A.3. Script para la exploración y creación de graficas de las variables representativas de la turbina de gas.

```

clc, clear, close all;

% Load raw data
f=readmatrix('Solar4s.xlsx');
d1 = f(:,3); % T01 - Inlet Temperature
d2 = f(:,4); % mf - Gas flow
d3 = f(:,5); % Ngp - Rotational Speed
d4 = f(:,6); % T05 - Exhaust Temperature
d5 = f(:,7); % P - Power

% Initialize variables
T01 = zeros(length(d1)/10,1);
mf = zeros(length(d2)/10,1);
Ngp = zeros(length(d3)/10,1);
T05 = zeros(length(d4)/10,1);
P = zeros(length(d5)/10,1);

len = length(T01);
for i = 1:len
    j = (i-1)*10 + 1;
    k = i*10;
    T01(i) = mean(d1(j:k));
    mf(i) = mean(d2(j:k));
    Ngp(i) = mean(d3(j:k));
    T05(i) = mean(d4(j:k));
    P(i) = mean(d5(j:k));
end

fprintf('T1: min = %4.1f, max = %4.1f\n', min(T01), max(T01));
fprintf('mf: min = %4.1f, max = %4.1f\n', min(mf), max(mf));
fprintf('Ngp: min = %4.1f, max = %4.1f\n', min(Ngp), max(Ngp));
fprintf('T05: min = %4.1f, max = %4.1f\n', min(T05), max(T05));
fprintf('P: min = %4.1f, max = %4.1f\n', min(P), max(P));

Nspeed = 14951; % PT Nominal Speed (60 Hz)
Ngp = Nspeed*Ngp*(1/100);

t = 1:1:len; t = t';
figure
plot(t,mf,'b','LineWidth',2), xlabel('Time [s]'), ylabel('mf [lb/h]')
grid on;
figure
plot(t,T01,'c','LineWidth',2), xlabel('Time [s]'), ylabel('T1 [degF]')
grid on;
figure
plot(t,P,'k','LineWidth',2), xlabel('Time [s]'), ylabel('P [kW]')
grid on;
figure
plot(t,Ngp,'r','LineWidth',2), xlabel('Time [s]'), ylabel('Ngp [rpm]')
grid on;
figure
plot(t,T05,'m','LineWidth',2), xlabel('Time [s]'), ylabel('T5 [degF]')
grid on;

```

A.4. Script para implementar la red NARX que permite predecir la salida de la velocidad de rotación (*Ngp*) en función de las entradas: temperatura de ingreso (*T1*) y caudal de flujo masico (*mf*).

```
% Solve an Autoregression Problem with External Input with a NARX Neural Network
% Script generated by Neural Time Series app
% This script assumes these variables are defined:
%
% T01 - input time series.
% mf - input time series.
% Ngp - output time series.
% T05 - output time series.

clc,clear,close all;

% Load raw data
F = readmatrix('Solar.xlsx');
d1 = f(:,3); % T01 - Inlet Temperature
d2 = f(:,4); % mf - Gas flow
d3 = f(:,5); % Ngp - Rotational Speed
d4 = f(:,6); % T05 - Exhaust Temperature
d5 = f(:,7); % P - Power

Nspeed = 14951; % PT Nominal Speed (60 Hz)

% Initialize variables
T01 = zeros(length(d1)/10,1);
mf = zeros(length(d2)/10,1);
Ngp = zeros(length(d3)/10,1);
T05 = zeros(length(d4)/10,1);
P = zeros(length(d5)/10,1);
len = length(T01);
for i = 1:len
    j = (i-1)*10 + 1;
    k = i*10;
    T01(i) = mean(d1(j:k));
    mf(i) = mean(d2(j:k));
    Ngp(i) = mean(d3(j:k));
    T05(i) = mean(d4(j:k));
    P(i) = mean(d5(j:k));
end

% Preprocessing. Standardizing inputs
[T01_n, ps1] = mapstd(T01');
[mf_n, ps2] = mapstd(mf');
[Ngp_n, ps3] = mapstd(Ngp');
[T05_n, ps4] = mapstd(T05');

inputs = [mf_n' T01'];
targets = Ngp_n';

% Data arrangement for NN
X = tonndata(inputs,false,false);
T = tonndata(targets,false,false);

trainFcn = 'trainlm'; % Levenberg-Marquardt backpropagation.

% Create a Nonlinear Autoregressive Network with External Input
```

```

inputDelays = 1:2;
feedbackDelays = 1:2;
hiddenLayerSize = 20;
net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize,'open',trainFcn);

% Prepare the Data for Training and Simulation
[x,xi,ai,t] = preparets(net,X,{},T);

% Setup Division of Data for Training, Validation, Testing
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'time'; % Divide up every sample
net.divideParam.trainRatio = 70/100;
net.divideParam.valRatio = 15/100;
net.divideParam.testRatio = 15/100;

% Choose a Performance Function
net.performFcn = 'mse'; % Mean Squared Error

% Choose Plot Functions
net.plotFcns = {'plotperform','plottrainstate','ploterrhist',...
    'plotregression','plotresponse','ploterrcorr','plotinerrcorr'};
net.trainParam.showWindow=true;
net.trainParam.showCommandLine=false;
net.trainParam.show=1;
net.trainParam.epochs=50;
net.trainParam.goal=1e-8;
net.trainParam.max_fail=25;

% Train the Network
[net,tr] = train(net,x,t,xi,ai);

% Test the Network
y = net(x,xi,ai);
e = gsubtract(t,y);
performance = perform(net,t,y);

% Recalculate Training, Validation and Test Performance
trainTargets = gmultiply(t,tr.trainMask);
valTargets = gmultiply(t,tr.valMask);
testTargets = gmultiply(t,tr.testMask);
trainPerformance = perform(net,trainTargets,y);
valPerformance = perform(net,valTargets,y);
testPerformance = perform(net,testTargets,y);

% View the Network
view(net)

% Closed Loop Network
netc = closeloop(net);
netc.name = [net.name ' - Closed Loop'];
%view(netc)
[xc,xic,aic,tc] = preparets(netc,X,{},T);
yc = netc(xc,xic,aic);
closedLoopPerformance = perform(net,tc,yc);

% Postprocessing
yp_n = cell2mat(yc);
yp = mapstd('reverse',yp_n, ps3); % For Ngp
%yp = mapstd('reverse',yp_n, ps4); % For T05

```

```

% Calculate Root Mean Squared Error (RMSE)
R2o = rmse(yp',Ngp(3:3000)); % For Ngp
%R2o = rmse(yp',T05(3:3000)); % For T05
fprintf('Root Mean Squared Error: %4.2f\n', R2o)

% Plot response
time1 = 1:1:3000;
time1 = time1';
time2 = 3:1:3000;
time2 = time2';

% For Ngp
figure
plot(time1,Ngp*Nspeed/100,'r')
xlabel('Time [s]'), ylabel('Ngp [rpm]')
hold on
plot(time2,yp*Nspeed/100,'b','LineWidth',1)
legend('Real system','NARX model')
grid on;

```



A.5. Script para graficar los resultados de simulación del modelo completo implementado en Simulink, que contiene los controladores diseñados para la velocidad de la turbina de gas. Se registraron las variables desde el bloque Scope en formato Dataset y los datos obtenidos fueron grabados en un archivo tipo “.mat”.

```

clear; clc; close all;
% Load data
load("C:\Matlab\datos_sim.mat");

% Plot controllers responses
% Fuel Stroke Reference
fsr1 = ScopeFsr{1}.Values.Data(:,1);
fsr2 = ScopeFsr{2}.Values.Data(:,1);
fsr3 = ScopeFsr{3}.Values.Data(:,1);
fsr4 = ScopeFsr{4}.Values.Data(:,1);
t = ScopeFsr{1}.Values.Time;

% Exhaust Temperature
tx1 = ScopeTx{1}.Values.Data(:,1);
tx2 = ScopeTx{2}.Values.Data(:,1);
tx3 = ScopeTx{3}.Values.Data(:,1);
tx4 = ScopeTx{4}.Values.Data(:,1);

% Rotational Speed
% Response governor speed controller
n1 = ScopeN{1}.Values.Data(:,1);
% Response pid controller
n2 = ScopeN{2}.Values.Data(:,1);
% Response RNA-mpc controller
n3 = ScopeN{3}.Values.Data(:,1);
% Response narma-12 controller
n4 = ScopeN{4}.Values.Data(:,1);
% Reference speed
r = ScopeN{5}.Values.Data(:,1);

figure(1)
plot(t, n1, 'Color', [1 0.65 0], 'LineWidth', 2)
grid on; hold on;
plot(t, n2, 'b', 'LineWidth', 2)
plot(t, n3, 'r', 'LineWidth', 2)
plot(t, n4, 'Color', [0 0.5 0], 'LineWidth', 2)
plot(t, r, 'r--', 'LineWidth', 1)
legend('Speed Governor', 'PID', 'RNA-MPC', 'NARMA-L2', 'Reference')
title('Controllers Performance')
xlabel('Time (s)')
ylabel('Rotational Speed [ p.u. ]')
set(gca,'FontSize', 14)

figure(2)
plot(t, fsr1, 'Color', [1 0.65 0], 'LineWidth', 2)
grid on; hold on;
plot(t, fsr2, 'b', 'LineWidth', 2)
plot(t, fsr3, 'r', 'LineWidth', 2)
plot(t, fsr4, 'Color', [0 0.5 0], 'LineWidth', 2)
legend('FSR1', 'FSR2', 'FSR3', 'FSR4')

```

```
title('Controllers Performance')
xlabel('Time (s)')
ylabel('Fuel Stroke Reference [ p.u. ]')
set(gca,'FontSize', 14)

figure(3)
plot(t, tx1, 'Color', [1 0.65 0], 'LineWidth', 2)
grid on; hold on;
plot(t, tx2, 'b', 'LineWidth', 2)
plot(t, tx3, 'r', 'LineWidth', 2)
plot(t, tx4, 'Color', [0 0.5 0], 'LineWidth', 2)
legend('Tx1', 'Tx2', 'Tx3', 'Tx4')
title('Controllers Performance')
xlabel('Time (s)')
ylabel('Exhaust Temperature [ degF ]')
set(gca,'FontSize', 14)
```



A.6. Ejemplo de código en lenguaje de texto estructurado (ST) para la plataforma Rockwell RSLogix 5000, generado por Simulink PLC Coder. Se utilizó como prototipo el controlador NARMA-L2 diseñado para la turbina de gas en el Capítulo 3.

```
(*
 * File: TestPLC.st
 * PLC Structured Text (ST) code generated for subsystem "TestPLC/NARMA-L2
Controller"
 *
 * Model name           : TestPLC
 * Model version        : 2.175
 * Model creator         : S
 * Model last modified by : S
 * Model last modified on  : Fri Jul 18 17:06:19 2025
 * Model sample time     : 0.01s
 * Subsystem name        : TestPLC/NARMA-L2 Controller
 * Subsystem sample time : 0.01s
 * Simulink PLC Coder version : 25.1 (R2025a) 21-Nov-2024
 * ST code generated on   : Fri Jul 04 17:06:38 2025
 *
 * Target IDE selection   : Rockwell RSLogix 5000: Routine
 * Test Bench included    : No
 *
 *)
FUNCTION_BLOCK NARMA
CASE i0_NARMA.ssMethodType OF
  0:
    (* SystemInitialize for Atomic SubSystem: '<Root>/NARMA-L2 Controller'
 *)
    (* InitializeConditions for UnitDelay: '<S1>/Unit Delay4' *)
    i0_NARMA.UnitDelay4_DSTATE := 0.0;
    (* InitializeConditions for DiscreteStateSpace: '<S1>/Discrete State-
Space4' *)
    i0_NARMA.b_DiscreteStateSpace4_DSTAT[0] := 1.0;
    i0_NARMA.b_DiscreteStateSpace4_DSTAT[1] := 1.0;
    (* End of SystemInitialize for SubSystem: '<Root>/NARMA-L2 Controller'
 *)
  1:
```

```

(* Outputs for Atomic SubSystem: '<Root>/NARMA-L2 Controller' *)
(* SignalConversion: '<S1>/TmpSignal ConversionAtDiscrete State-
Space4Inport1' incorporates:
    * UnitDelay: '<S1>/Unit Delay4' *)
i0_NARMA.c_TmpSignalConversionAtDisc := i0_NARMA.UnitDelay4_DSTATE;
(* End of Outputs for SubSystem: '<Root>/NARMA-L2 Controller' *)

(* DiscreteStateSpace: '<S1>/Discrete State-Space4' *)
(* Outputs for Atomic SubSystem: '<Root>/NARMA-L2 Controller' *)
(* DiscreteStateSpace: '<S1>/Discrete State-Space4' incorporates:
    * Switch: '<S1>/Switch1'
    * UnitDelay: '<S1>/Unit Delay4' *)
i0_NARMA.DiscreteStateSpace4_DSTATE :=
i0_NARMA.b_DiscreteStateSpace4_DSTAT[1];
i0_NARMA.DiscreteStateSpace4_DSTATEv :=
i0_NARMA.b_DiscreteStateSpace4_DSTAT[0];
FOR i0_NARMA.i := 0 TO 2 DO
    i0_NARMA.temp1 := i0_NARMA.i + 3;
    i0_NARMA.temp2 := i0_NARMA.i + 3;
    i0_NARMA.rtb_DiscreteStateSpace4[i0_NARMA.i] :=
(((i0_NARMA.DiscreteStateSpace4_C[i0_NARMA.temp1] *
i0_NARMA.DiscreteStateSpace4_DSTATE) +
(i0_NARMA.DiscreteStateSpace4_C[i0_NARMA.i] *
i0_NARMA.DiscreteStateSpace4_DSTATEv)) +
(i0_NARMA.DiscreteStateSpace4_D[i0_NARMA.i] * i0_NARMA.PlantOutput)) +
(i0_NARMA.DiscreteStateSpace4_D[i0_NARMA.temp2] * i0_NARMA.UnitDelay4_DSTATE);
END_FOR;
(* End of DiscreteStateSpace: '<S1>/Discrete State-Space4' *)

(* Gain: '<S1>/Matrix Gain2' *)
i0_NARMA.DiscreteStateSpace4_DSTATE := 0.0;
(* Gain: '<S1>/Matrix Gain3' *)
i0_NARMA.DiscreteStateSpace4_DSTATEv := 0.0;
(* Gain: '<S1>/Matrix Gain' *)
i0_NARMA.rtb_DiscreteStateSpace4_0 :=
i0_NARMA.rtb_DiscreteStateSpace4[1];
i0_NARMA.rtb_DiscreteStateSpace4_1 :=
i0_NARMA.rtb_DiscreteStateSpace4[0];

```

```

i0_NARMA.rtb_DiscreteStateSpace4_2 :=
i0_NARMA.rtb_DiscreteStateSpace4[2];
FOR i0_NARMA.i := 0 TO 19 DO
  (* Gain: '<S1>/Matrix Gain2' incorporates:
  * Constant: '<S1>/Constant'
  * Constant: '<S8>/one'
  * Constant: '<S8>/one1'
  * Gain: '<S1>/Matrix Gain'
  * Gain: '<S8>/Gain'
  * Gain: '<S8>/Gain1'
  * Math: '<S8>/Exp'
  * Math: '<S8>/Reciprocal'
  * Sum: '<S2>/netsum'
  * Sum: '<S8>/Sum'
  * Sum: '<S8>/Sum1'
  *
  * About '<S8>/Exp':
  * Operator: exp
  *
  * About '<S8>/Reciprocal':
  * Operator: reciprocal *)
  i0_NARMA.temp1 := i0_NARMA.i + 20;
  i0_NARMA.temp2 := i0_NARMA.i + 40;
  i0_NARMA.DiscreteStateSpace4_DSTATE := (((1.0 / (2.7182818284590451
** (((i0_NARMA.MatrixGain_Gain[i0_NARMA.temp1] *
i0_NARMA.rtb_DiscreteStateSpace4_0) + (i0_NARMA.MatrixGain_Gain[i0_NARMA.i] *
i0_NARMA.rtb_DiscreteStateSpace4_1)) + (i0_NARMA.MatrixGain_Gain[i0_NARMA.temp2]
* i0_NARMA.rtb_DiscreteStateSpace4_2)) + i0_NARMA.Constant_Value[i0_NARMA.i]) *
-2.0) + 1.0)) * 2.0) - 1.0) * i0_NARMA.MatrixGain2_Gain[i0_NARMA.i]) +
i0_NARMA.DiscreteStateSpace4_DSTATE;
  (* Gain: '<S1>/Matrix Gain3' incorporates:
  * Constant: '<S1>/Constant5'
  * Constant: '<S9>/one'
  * Constant: '<S9>/one1'
  * Gain: '<S1>/Matrix Gain1'
  * Gain: '<S9>/Gain'
  * Gain: '<S9>/Gain1'
  * Math: '<S9>/Exp'
  * Math: '<S9>/Reciprocal'

```

```

* Sum: '<S4>/netsum'
* Sum: '<S9>/Sum'
* Sum: '<S9>/Sum1'
*
* About '<S9>/Exp':
* Operator: exp
*
* About '<S9>/Reciprocal':
* Operator: reciprocal *)
i0_NARMA.temp1 := i0_NARMA.i + 20;
i0_NARMA.temp2 := i0_NARMA.i + 40;
i0_NARMA.DiscreteStateSpace4_DSTATEv := (((1.0 /
(2.7182818284590451 ** (((((i0_NARMA.MatrixGain1_Gain[i0_NARMA.temp1] *
i0_NARMA.rtb_DiscreteStateSpace4_0) + (i0_NARMA.MatrixGain1_Gain[i0_NARMA.i] *
i0_NARMA.rtb_DiscreteStateSpace4_1)) +
(i0_NARMA.MatrixGain1_Gain[i0_NARMA.temp2] *
i0_NARMA.rtb_DiscreteStateSpace4_2)) + i0_NARMA.Constant5_Value[i0_NARMA.i]) * -
2.0) + 1.0)) * 2.0) - 1.0) * i0_NARMA.MatrixGain3_Gain[i0_NARMA.i]) +
i0_NARMA.DiscreteStateSpace4_DSTATEv;
END_FOR;
(* Switch: '<S1>/Switch2' incorporates:
* Gain: '<S1>/Matrix Gain5'
* Gain: '<S1>/Matrix Gain8'
* Product: '<S1>/Product'
* Sum: '<S1>/Sum'
* Sum: '<S3>/netsum1'
* Sum: '<S5>/netsum1'
* Switch: '<S1>/Switch3' *)
i0_NARMA.ControlSignal := (i0_NARMA.b_Reference -
(((i0_NARMA.DiscreteStateSpace4_DSTATE - 1.9412960197757672) * -
0.17918460824646926)) / ((i0_NARMA.DiscreteStateSpace4_DSTATEv -
2.2253707100594462) * -0.010009348717986432);
(* Saturate: '<S1>/Saturation1' *)
IF i0_NARMA.ControlSignal > 0.4 THEN
    i0_NARMA.ControlSignal := 0.4;
ELSIF i0_NARMA.ControlSignal < -0.4 THEN
    i0_NARMA.ControlSignal := -0.4;
END_IF;
(* End of Saturate: '<S1>/Saturation1' *)

```

```

(* Update for UnitDelay: '<S1>/Unit Delay4' incorporates:
 * Switch: '<S1>/Switch' *)
i0_NARMA.UnitDelay4_DSTATE := i0_NARMA.ControlSignal;
(* Update for DiscreteStateSpace: '<S1>/Discrete State-Space4'
incorporates:
 * Switch: '<S1>/Switch1' *)
i0_NARMA.b_DiscreteStateSpace4_DSTAT[0] := i0_NARMA.PlantOutput;
i0_NARMA.b_DiscreteStateSpace4_DSTAT[1] :=
i0_NARMA.c_TmpSignalConversionAtDisc;
(* End of Outputs for SubSystem: '<Root>/NARMA-L2 Controller' *)
END_CASE;
END_FUNCTION_BLOCK
TYPE NARMAUDT:
STRUCT
    ssMethodType: SINT;
    b_Reference: REAL;
    PlantOutput: REAL;
    ControlSignal: REAL;
    i: DINT;
    rtb_DiscreteStateSpace4: ARRAY [0..2] OF REAL;
    c_TmpSignalConversionAtDisc: REAL;
    rtb_DiscreteStateSpace4_0: REAL;
    rtb_DiscreteStateSpace4_1: REAL;
    rtb_DiscreteStateSpace4_2: REAL;
    DiscreteStateSpace4_DSTATE: REAL;
    DiscreteStateSpace4_DSTATEv: REAL;
    UnitDelay4_DSTATE: REAL;
    b_DiscreteStateSpace4_DSTAT: ARRAY [0..1] OF REAL;
    MatrixGain2_Gain: ARRAY [0..19] OF REAL;
    MatrixGain3_Gain: ARRAY [0..19] OF REAL;
    DiscreteStateSpace4_D: ARRAY [0..5] OF REAL;
    DiscreteStateSpace4_C: ARRAY [0..5] OF REAL;
    Constant_Value: ARRAY [0..19] OF REAL;
    Constant5_Value: ARRAY [0..19] OF REAL;
    MatrixGain_Gain: ARRAY [0..59] OF REAL;
    MatrixGain1_Gain: ARRAY [0..59] OF REAL;
    temp1: DINT;
    temp2: DINT;

```

```

END_STRUCT
END_TYPE
VAR_GLOBAL
    i0_NARMA: NARMAUDT := (
ssMethodType:=0,b_Reference:=0.0,PlantOutput:=0.0,ControlSignal:=0.0,i:=0,

rtb_DiscreteStateSpace4:=0.0,0.0,0.0,c_TmpSignalConversionAtDisc:=0.0,rtb_DiscreteStateSpace4_0:=0.0,

rtb_DiscreteStateSpace4_1:=0.0,rtb_DiscreteStateSpace4_2:=0.0,DiscreteStateSpace4_DSTATE:=0.0,

DiscreteStateSpace4_DSTATEv:=0.0,UnitDelay4_DSTATE:=0.0,b_DiscreteStateSpace4_DS
TAT:=0.0,0.0,
    MatrixGain2_Gain:=-0.00078635882513731169,-0.023994588433627527,-
1.4338758434074674,-0.0046074320130678427,
    -0.0046841380633452605,0.0020678496205338995,-
0.00016084302168899839,0.0736843331413315,
    -0.11150068327100882,-0.035797750522857164,0.17530120299834082,-
0.23091892330788261,0.00013247190845158365,
    0.026690733333840207,-0.0010294458637995325,-0.0046082059370788821,-
0.05110420940261589,0.18046329269258221,
    0.066700583113300127,-
2.2775023898896078,MatrixGain3_Gain:=0.8829796559968337,0.52321390666642853,
    0.51378318956084967,1.3428379843493259,0.0452289400204328,-
0.031747415595623288,-0.4931132629448689,
    0.18048527242677434,0.47101418870814615,-0.52885404726602525,-
0.23940124089525838,1.314037667432556,
    0.23603139646779053,-0.10132525216694223,0.80570601442384915,-
0.63548382466549913,-0.2622258518512946,
    -
1.6465072675919068,0.60228415516976064,0.043655035969040329,DiscreteStateSpace4_
D:=1.0,0.0,0.0,0.0,0.0,1.0,

DiscreteStateSpace4_C:=0.0,1.0,0.0,0.0,0.0,0.0,Constant_Value:=10.52946167819758
6,-47.991455888085227,
    28.775388501249289,54.189502104394968,-
44.508134762196967,37.7805913888049,4.1797354735503554,

```

33.357858501085381, -2.2260357699447031, -
44.360604217785919, 3.896043284282503, -7.6330061568129137,
2.8712772767431427, 29.191036159952795, -6.7290946583499487, -
23.542403650454162, -46.170228434206194,
19.575942734001643, 47.026495848145764, 27.671483113546362, Constant5_Value:=27.121
7105937503,
-57.646682357894939, 57.244836295542932, -
51.473023051680535, 54.388999954924614, 42.056998837003782,
-47.482604133872243, 52.589575627173275, -44.154250559775541, -
36.772289224677493, 32.706022958121707,
-13.109541955073523, 37.066879442058294, -
11.025219913012657, 1.2485764023021872, 7.0892115456135469,
-8.4437052464004463, 5.6722165728638227, -19.725585622527245, -
18.902183145438826, MatrixGain_Gain:=
8.3035279100008381, 16.790453912505892, -28.693480969410075, -
26.11078493867829, 19.137562061716906,
-8.92288936816493, 23.359087514737993, -10.978927864273386, -
22.391646276783884, 10.644474909122957,
-28.163319374431303, 27.993346951810434, 12.685989128958907, -
30.487469663140018, 0.5922714193676486,
26.746352454603908, 23.422995413815812, 0.96895231173009566, -
27.148097662646087, 13.98336718494893,
-20.930582905599035, 29.430018953644755, 7.7217058643379684, -
23.30961284068902, 21.686971337426794,
-26.820887191774663, -26.762159862694826, -
22.334090204647584, 24.7422325033449, 35.316294149663037,
23.588882404316784, -21.258731957812067, -
14.16942938908292, 0.24086248469581589, 5.4430436806958724,
-3.4250463922794316, 25.933302263765668, -18.96621690927978, -
24.81345907029711, -35.423272155011936,
6.8485057171595987, 3.744829656129665, 5.108652807015412, 1.9631933122652661, -
5.5152270339477125,
4.4437715322753322, 3.2505849678171654, -
2.773712369254238, 2.3289160129908577, 4.0218736742306485,
1.6331588717807455, -1.6036966331293874, 8.1840668204428439, -
0.54118661863912076, 8.4684551711911666,

```

-3.5465630791920177,3.0529690570948858,-2.2876023014580027,-
2.9140088058208273,-0.77310114559203591,
    MatrixGain1_Gain:=5.3076864750176833,26.065232902775865,-
27.290248124998811,33.58784117289342,
    -26.631750312902913,-20.823296539384444,28.620125036523021,-
24.4526650943558,22.153711947972472,
    20.618166968120864,-37.124630524098635,-21.842474706514267,-
30.727970438295284,-14.829430313938351,
-
27.609831424009531,19.552237138489744,27.608124182951091,25.910609988820116,-
18.29445031627948,
    8.7275297893967654,-36.272793556693891,28.391780573615197,-
26.879576498783688,12.052231473574146,
    -26.648347694884681,-18.436366450360772,16.008077274488048,-
27.614689726569814,19.255265657503685,
    13.557557604710198,5.84244950391811,30.720502658738535,-
7.56706070020719,26.281448514167174,
    26.308624816758371,-22.574249000850276,-16.3879148786646,-
27.992740126233226,33.880266704090864,
    13.052135276372059,-2.47392061045906,-
1.3344801901905001,0.24265847043281891,-4.0793014175121334,
    -2.1277851259528808,6.8512662183704043,-
4.0963130544545487,2.3396079505874305,6.43868815294922,
    6.2891598695120585,1.0965231762708925,-
1.1188370037000326,3.1617181606115121,-5.8374008052495094,
    1.098459300907114,-5.7529631507467629,-5.0775335220792845,-
1.168960903412922,-0.16352344091971383,
    8.71819323155069,temp1:=0,temp2:=0);
END_VAR

```