



POSGRADO INTERINSTITUCIONAL EN CIENCIA Y TECNOLOGÍA

CENTRO DE INGENIERÍA Y DESARROLLO INDUSTRIAL

**CARACTERIZACIÓN DE UN PROCESO
DE COMBUSTIÓN MEDIANTE UNA RED
NEURONAL ARTIFICIAL ENTRENADA
CON ALGORITMOS GENÉTICOS**

TESIS

QUE PARA OBTENER EL GRADO
ACADÉMICO DE:


**MAESTRO EN CIENCIA Y TECNOLOGÍA EN LA
ESPECIALIDAD DE MECATRÓNICA**

PRESENTA

ING. JUAN CARLOS GÓMEZ GARCÍA

ASESORES

**DR. FERNANDO HERNÁNDEZ ROSALES
DR. CARLOS A. COELLO COELLO**



CIENCIA Y TECNOLOGÍA

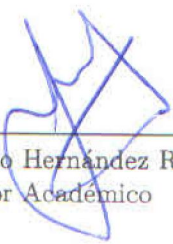
SANTIAGO DE QUERÉTARO, QUERÉTARO, MAYO DE 2014



Director de Posgrado
PICYT-CIDESI
Querétaro

Los abajo firmantes, miembros del Comité Tutorial del alumno Juan Carlos Gómez García, una vez leída y revisada la Tesis titulada "**Caracterización de un Proceso de Combustión mediante una Red Neuronal Artificial Entrenada con Algoritmos Genéticos**", aceptamos que la referida tesis revisada y corregida sea presentada por el alumno para aspirar al grado de Maestría en Ciencia y Tecnología en la opción terminal de Mecatrónica durante el Examen de Grado correspondiente.

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



Dr. Fernando Hernández Rosales
Tutor Académico



Dr. Carlos A. Coello Coello
Cotutor Académico



Director de Posgrado
PICYT-CIDESI
Querétaro

Los abajo firmantes, miembros del Jurado del Examen de Grado del alumno Juan Carlos Gómez García, una vez leída y revisada la Tesis titulada **”Caracterización de un Proceso de Combustión mediante una Red Neuronal Artificial Entrenada con Algoritmos Genéticos”**, aceptamos que la referida tesis revisada y corregida sea presentada por el alumno para aspirar al grado de Maestro en Ciencia y Tecnología en la Especialidad de Mecatrónica durante el Examen de Grado correspondiente.

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

Dr. Hugo Jiménez Hernández
Presidente

MC. Guillermo Ronquillo Lomelí
Secretario

Dr. Fernando Hernández Rosales
Vocal

Resumen

En este trabajo de investigación se presenta un Algoritmo Genético (AG) desarrollado para el entrenamiento de una Red Neuronal Artificial (RNA) la cual tiene como objetivo la caracterización de un proceso de combustión a través de la clasificación de diferentes patrones de flama.

El estudio se fundamenta en el análisis de la señal electromagnética de la flama adquirida con un detector. La clasificación de los patrones de flama se realiza mediante una Red Neuronal Artificial que emplea descriptores o características que son extraídas de la señal de flama, tales como los momentos estadísticos, la suma de autocorrelación, los componentes principales, la entropía y características relacionadas con señales oscilatorias. Además, una parte del análisis incluye también parámetros de la combustión (exceso de oxígeno y presión del combustible), que en conjunto con los descriptores sirven de entrada a la Red Neuronal Artificial.

El desarrollo de la investigación incluye un análisis inicial del sistema de clasificación de señales de un proceso de combustión con 4 estados de flama llevado a cabo en un laboratorio de pruebas así como pruebas finales con señales electromagnéticas de 5 estados de un proceso de combustión real en un sistema de quemadores de pared opuesta.

En el primer capítulo se presenta la descripción y planteamiento del problema, la justificación, la formulación de la hipótesis y se establecen los objetivos de la investigación. En el segundo capítulo se hace una descripción del proceso de la combustión y técnicas de monitoreo actuales, además de presentarse la descripción y fundamentos de las técnicas utilizadas en el proceso de investigación realizado. El tercer capítulo contiene el desarrollo de la metodología, incluyendo una descripción de las diferentes etapas y procesos llevados a cabo. Mientras tanto, el capítulo cuatro corresponde a los resultados obtenidos que incluyen las pruebas de laboratorio y la clasificación de pruebas de un proceso real de combustión; este apartado además muestra los resultados preliminares del desarrollo de un Algoritmo Genético para la evolución automática de la arquitectura y entrenamiento de una

Red Neuronal Artificial. Finalmente, en el capítulo cinco se presentan las conclusiones del trabajo así como algunas posibles líneas de trabajo futuro.

Dedicatoria

Dedico este triunfo con mucho amor y cariño a mis padres: El Sr. Crescenciano Gómez Anselmo, mi papá, y La Sra. Tomasa García Franco, mi mamá. Por todo el esfuerzo que han hecho por brindarme más allá de lo que ha sido necesario, porque gracias a ustedes he aprendido a luchar en la vida para alcanzar mis metas y porque me han enseñado que el único verdadero obstaculo entre ellas es uno mismo. Gracia, porque lo que he logrado y la persona en la que hoy me convertido ha sido por ustedes, por su cariño, su amor y su afecto.

Agradecimientos

Quiero agradecer en primer lugar a mi familia, que ha estado en mi corazón, apoyándome siempre. A mi papá, a mi mamá y a mis hermanas, gracias por su cariño y afecto que ha sido un gran impulso para mi.

Al Dr. Fernando Hernandez, mi asesor, le agradezco por brindarme esta oportunidad de crecer profesionalmente. Por permitirme realizar esta investigación a su lado y por todo el apoyo que me ha dado a lo largo de ésta.

Al Dr. Carlos A. Coello, mi co-asesor, gracias por su tiempo, su gran apoyo, asesoría y colaboración en los temas abordados en la presente tesis.

Al Dr. Hugo Jimenez y M.C. Guillermo Ronquillo con los cuales he tenido la oportunidad de abordar pláticas interesantes que me ayudaron en mi desarrollo y en mi trayecto recorrido a lo largo de la maestría.

A su vez, quiero extender también este agradecimiento al Ing. Rodolfo Coria y al Ing. Antonio Trejo que han sido parte indispensable en este proyecto.

Y a todos mis amigos que me han acompañado este tiempo y con los cuales he compartido tan valiosos momentos.

A Todos Ustedes !Muchas Gracias!

Índice General

Resumen	I
Dedicatoria	III
Agradecimientos	IV
Lista de Figuras	VIII
Lista de Tablas	X
Abreviaturas	XI
1 Introducción	1
1.1 Antecedentes	1
1.2 Definición del problema	2
1.3 Justificación	3
1.4 Objetivo general	5
1.5 Objetivos específicos	5
1.6 Hipótesis	5
2 Marco Teórico	6
2.1 Combustión	6
2.1.1 Combustión estequiométrica	7
2.2 Patrones de flama	9
2.2.1 Tipos de flamas	9
2.3 Radiación electromagnética	12
2.3.1 Espectroscopía	12
2.4 Monitoreo de la combustión	14
2.4.1 Electroscopía de las flamas	14
2.4.1.1 Quimioluminiscencia	15
2.4.1.2 Espectroscopía de absorción láser	16
2.4.1.3 Emisión espontánea como patrón de flama	17
2.4.2 Técnicas mediante imágenes	18

2.4.3	Transductores de presión	19
2.5	Pre-procesamiento de señales	20
2.6	Redes Neuronales Artificiales	20
2.6.1	Topología de una RNA	22
2.6.2	Tipo de Entrenamiento	23
2.6.3	Regla de Aprendizaje	23
2.6.4	Retropropagación	24
2.7	Algoritmo Genético	25
2.7.1	Representación	26
2.7.2	Operadores genéticos	30
2.7.3	Selección	31
2.7.4	Cruce	31
2.7.5	Mutación	33
2.7.6	Teorema de los esquemas	34
2.7.7	Hipótesis de los Bloques Constructores	35
2.8	Aplicación de los Algoritmos Genéticos a las Redes Neuronales	36
2.8.1	Evolución de los pesos	37
2.8.2	Evolución de la arquitectura.	37
2.8.3	Evolución de reglas de aprendizaje	38
3	Metodología	39
3.1	Adquisición de la señal	40
3.1.1	Señales de laboratorio	41
3.1.2	Señales del proceso real de combustión en la unidad de quemadores	42
3.2	Pre-procesamiento de la señal	44
3.2.1	Características estadísticas	45
3.2.1.1	Momentos estadísticos	45
3.2.1.2	Autocorrelación	45
3.2.2	Análisis de Componentes Principales (PCA)	46
3.2.3	Características de señales oscilatorias	48
3.2.4	Entropía	49
3.3	Implementación del Algoritmo Genético y la Red Neuronal Artificial	51
3.3.1	Parámetros de la Red Neuronal Artificial implementada	52
3.3.2	Codificación de la Red Neuronal Artificial	53
3.3.3	Modelo del Algoritmo Genético implementado	54
3.3.3.1	Función de aptitud	56
3.3.3.2	Selección	57
3.3.3.3	Cruza	57
3.3.3.4	Mutación	57
3.3.3.5	Eliminación de conexiones	58
4	Resultados	59
4.1	Comportamiento de la función de aptitud	59
4.2	Clasificación de las señales de laboratorio	61
4.2.1	Representación de la matriz de adyacencias como imagen	63
4.3	Clasificación de las señales de la unidad de quemadores	67
4.4	Entrenamiento y evolución de la arquitectura	69

5 Conclusiones y Recomendaciones	75
5.1 Objetivos alcanzados	75
5.2 Conclusiones	76
5.3 Recomendaciones y trabajo futuro	77
Anexos	78
A Diagrama conceptual de un Algoritmo Genético	78
B Características extraídas de las señales de la unidad de quemadores	79
Anexos	82
C Tipos de flamas	82
D Publicación	83
Bibliografía	84

Lista de Figuras

1.1	Tendencias del consumo de combustibles a nivel mundial	2
1.2	Enfoque de la problemática en la Combustión	4
2.1	Esquema de la combustión	7
2.2	Combustión estequiométrica del metano	8
2.3	Exceso de aire	9
2.4	Modelo de Mallard-Le Chatellierd	11
2.5	Regiones del espectro electromagnético	13
2.6	Intensidad de radiación de diferentes combustibles	15
2.7	Sistema de detección de gases mediante TDLA	16
2.8	Diagrama conceptual del monitoreo mediante imágenes	19
2.9	Esquemas de una neurona.	21
2.10	Funciones de transferencia.	22
2.11	Red neuronal perceptrón multicapa.	23
2.12	Esquema general de un Algoritmo Genético.	26
2.13	Trasformación del espacio de búsqueda	27
2.14	Tipos de representación	28
2.15	Características de la representación	30
2.16	Operador de cruce en representaciones binarias	32
2.17	Mutación binaria	33
2.18	Definición de Esquema.	34
3.1	Metodología construida para la caracterización de los patrones de flama	40
3.2	Diagrama de adquisición de datos con el detector de flama	41
3.3	Señales de los patrones de laboratorio	42
3.4	Disposición de los quemadores del sistema de combustión	43
3.5	Señales de los quemadores	44
3.6	Aplicación de PCA en las señales del detector	47
3.7	Selección de los Componentes Principales	48
3.8	Entrenamiento de la Red Neuronal mediante un Algoritmo Genético	51
3.9	Representación de la Red Neuronal como una matriz de adyacencias	53
3.10	Patrones de salida de la Red Neuronal	54
3.11	Codificación de la Red Neuronal	54

3.12	Operador de eliminación de conexiones	58
4.1	Comportamiento de la función de aptitud	60
4.2	Comparación de la Ec. 3.25 vs error cuadrático como función de aptitud	61
4.3	Entrenamiento con cruza Aritmética Total	62
4.4	Evolución de las matrices de pesos: Cruza en 2 Puntos	64
4.5	Evolución de las matrices de pesos: Aritmética Total	64
4.6	Evolución de las matrices de pesos: Cruza SBX	65
4.7	Evolución de las matrices de pesos: Cruza Uniforme	66
4.8	Entrenamiento de la RNA con señales de la unidad de quemadores	69
4.9	Representación de la RNA con conexiones entre capas mediante la matriz de adyacencias	70
4.10	Matriz de pesos de una RNA con conexiones completas	70
4.11	Entrenamiento y evolución de la arquitectura con Cruza Uniforme: Señales de laboratorio	73
C.1	Estructura de una llama laminar.	82

Lista de Tablas

2.1	Composición del aire seco	6
2.2	Mutación para representación con valores reales	34
3.1	Parámetros del sistema de quemadores	43
3.2	Bases de datos de las señales	52
3.3	Parámetros de la Red Neuronal Artificial	53
3.4	Características del Algoritmo Genético implementado	55
3.5	Parámetros de los tipos de cruza	57
4.1	Comparación de la función de aptitud: Ec. 3.25 y error cuadrático	60
4.2	Resumen del entrenamiento con diferentes tipos de cruza (Datos de laboratorio)	61
4.3	Cruza Aritmética: Pruebas con diferentes neuronas en la capa oculta	62
4.4	Clasificación con una RNA de 6 neuronas: Señales del proceso real	67
4.5	Clasificación con una RNA de 10 neuronas: Señales de los quemadores	68
4.6	Resultados de la clasificación con la RNA obtenida del AG con entrenamiento y evolución de arquitectura: Señales de laboratorio	72
C.1	Tipos de flama según tipo de mezcla y tipo de flujo	82

Abreviaturas

AG	A lgoritmo G enético
CCD	C harge- C oupled D evice
EGR	E xhaust G as R ecirculation
EMM	E spectro E lectromagnético
HMI	H uman M achine I nterface
ICA	I ndependent C omponent A nalysis
IR	I nfrarrojo
LDA	L ineal D ependent A nalysis
MSD	M ultidimensional S caling
MSE	M ean S quared E rror
PCA	P rincipal C omponents A nalisis
RNA	R ed N eural A rtificial
SBX	S imulated B inary C rossover
SVD	S ingular V alue D ecomposition
TDLAS	T unable D iode L aser A bsorption S pectroscopy
UV	U ltra V ioleta

Capítulo 1

Introducción

1.1 Antecedentes

Hoy en día, la generación de energía mediante nuevas tecnologías, se encuentra estrechamente ligada con un fuerte compromiso hacia la protección del medio ambiente y la reducción en la emisión de contaminantes. La energía eléctrica por su parte se ha tornado un elemento necesario dentro de nuestra sociedad, viéndose involucrada en nuestra vida cotidiana en actividades básicas que van desde la generación y producción de alimentos y el transporte, hasta servicios y actividades recreativas y de diversión.

Los sistemas actuales de generación de energía incluyen tecnologías como la solar, hidroeléctrica, nuclear y eólica, entre otras. Sin embargo, los combustibles fósiles continúan siendo la principal fuente de generación de energía eléctrica tanto en países desarrollados como en países en vías de desarrollo. Como se puede observar en la figura 1.1, el consumo de combustibles fósiles se encuentra muy por encima de las fuentes de generación de energía alternativas; mientras tanto, en la segunda gráfica se observa que la generación de energía eléctrica a nivel mundial está liderada a su vez por los combustibles fósiles, es decir las tendencias a nivel mundial del uso de combustibles fósiles continuará por un periodo considerable.

Por su parte, en el año 2010, en México, los sistemas de producción de energía eléctrica mediante la quema de combustibles fósiles abarcaban más del 73% del total de las fuentes energéticas y las proyecciones para el año 2026 [7] indican que esta tendencia, si bien disminuirá, se estima tendrá un porcentaje del 62% que es aún considerablemente alto en comparación con las otras tecnologías de generación de energía eléctrica.

Además de los sistemas de generación de energía, el proceso de la combustión es de gran importancia dentro de la industria, siendo ampliamente usado en sistemas como hornos, calderas,

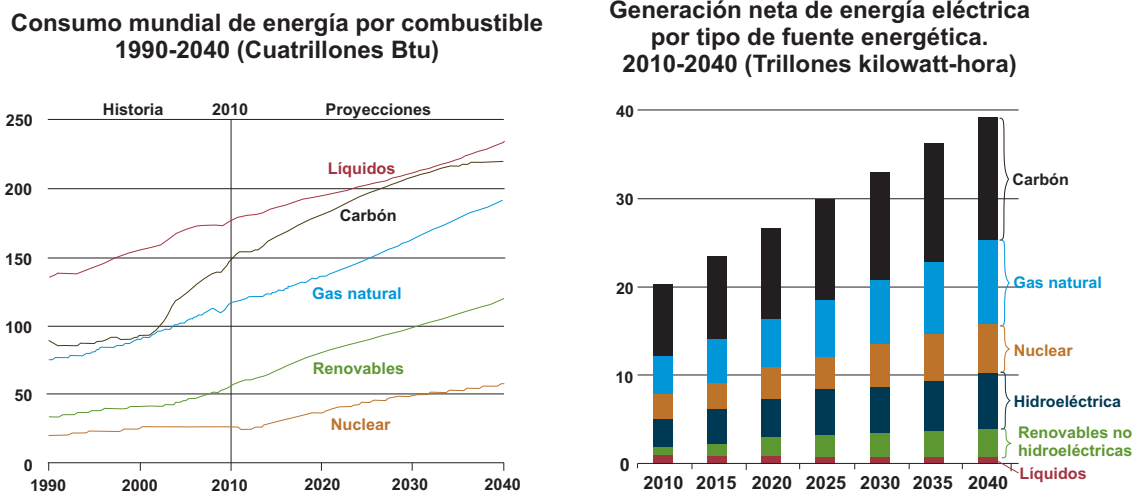


Figura 1.1: Tendencias del consumo de combustibles a nivel mundial [12]

quemadores, boilers, sistemas de calefacción, transporte y sistemas de co-generación, entre otros. Estos sistemas requieren del desarrollo continuo de nuevas tecnologías a través de las cuales se pueda incrementar su desempeño y eficiencia.

A través del monitoreo y seguimiento de la combustión se pueden desarrollar sistemas que ofrezcan mayores beneficios, sin embargo la combustión es un fenómeno muy complejo en el que se encuentran involucradas una gran diversidad de áreas tales como la mecánica de fluidos, transferencia de calor, cinemática química, etc. [33]. Esta interacción y complejidad ha llamado la atención de la comunidad científica que busca generar nuevos conocimientos y a través de los cuales se puedan comprender mejor los procesos involucrados en la combustión.

Con esta finalidad, diversas metodologías han sido empleadas en sistemas de combustión, teniendo entre ellas a la Lógica Difusa [55], los Sistemas Expertos [36], las Máquinas de Vectores de Soporte [52], las Redes Neuronales Artificiales [32] y los Algoritmos Genéticos [22, 27]. Sin embargo, estas aplicaciones han sido enfocadas mayormente al análisis y predicción de los gases producto de la combustión y en menor medida al análisis de la combustión a través del monitoreo de su estado actual.

1.2 Definición del problema

Los combustibles fósiles hoy en día son la principal fuente de generación de energía eléctrica. Estos sistemas de generación de energía requieren sistemas de control y seguimiento a través de los cuales se logre una mayor eficiencia en la quema de combustible haciéndolos más seguros, confiables y reduciendo la emisión de contaminantes atmosféricos.

El fenómeno de la combustión es caracterizado por ser un proceso estocástico, tener una dinámica altamente no lineal y ser multivariable. Sumado a esto, se tienen las condiciones y parámetros de

operación tales como tipo de combustible, temperaturas, flujos, presión, entre otros, así como factores mecánicos y de diseño de los equipos en los que se lleva a cabo la combustión. La complejidad de estas dinámicas presentes en el proceso lo hace difícil de modelar mediante métodos matemáticos deterministas comúnmente usados.

Esto convierte a la combustión en un fuerte candidato para ser tratada mediante metodologías libres del modelo tales como las Redes Neuronales Artificiales que son sistemas robustos, tolerantes al ruido y tienen la habilidad de generalización hacia nuevos datos [5]. Sin embargo, la implementación de estas metodologías está basada en la selección apropiada de sus parámetros que es realizada generalmente mediante un proceso de ensayo y error.

La exitosa aplicación de las Redes Neuronales en el modelado de problemas, por su parte, está ampliamente influenciada por factores tales como la arquitectura, el tipo de función de activación y el tipo de entrenamiento. De este modo diferentes tipos de arquitecturas pueden tener un desempeño similar y arquitecturas semejantes pueden tener un desempeño completamente diferentes [56].

El entrenamiento de las Redes Neuronales, por su parte, es un problema abierto y puede ser visto como un problema de optimización. Una forma de superar las deficiencias es considerar el proceso de entrenamiento como una evolución de los pesos de las conexiones hacia un conjunto óptimo (o cercano al óptimo) definido por una función objetivo y el entrenamiento como el medio ambiente en el cual ocurre la evolución, evitando así el desarrollo e implementación de Redes Neuronales mediante prueba y error.

1.3 Justificación

La combustión es ampliamente usada en la industria en aplicaciones como la calefacción y generación de energía y transporte. Mejorar el proceso de combustión permitiría incrementar la eficiencia de estos sistemas haciéndolos más rentables, seguros, fiables y reduciendo a la vez la generación de contaminantes. A través del monitoreo y seguimiento de la combustión se puede realizar un control del proceso, manteniéndolo bajo condiciones de operación estables.

Las condiciones cambiantes y la dinámica compleja de la combustión hacen necesario el uso de un sistema que sea capaz de ajustarse a dichas condiciones y que pueda generalizar el conocimiento de los patrones de flama a condiciones nuevas. Los modelos como las Redes Neuronales Artificiales, debido a sus características de tolerancia al ruido y capacidad de generalización del conocimiento hacia nuevos datos, ofrecen una alternativa a sistemas en los que la determinación de un modelo que lo gobierna es complejo de obtener. Aunado a ello, los Algoritmos Genéticos presentan ventajas que pueden ser explotadas para su uso en el entrenamiento y generación automática de la arquitectura de una Red Neuronal.

En la actualidad, los sistemas de combustión reales, cuentan con detectores de flama como dispositivos de seguridad, que indican la presencia o ausencia de la flama, basándose principalmente en la captación de la radiación emitida por la flama durante la combustión. Estos dispositivos pueden ser usados para caracterizar el proceso de la combustión si se extrae información de la señal electromagnética que pueda ser útil. La caracterización del comportamiento de un proceso de combustión mediante el análisis de la señal electromagnética permitiría ampliar el uso y aplicación de componentes ya usados en la industria de la generación de energía, reduciendo costos e implementación de dispositivos de seguimiento de la combustión.

En la figura 1.2 se presenta esquemáticamente este enfoque.

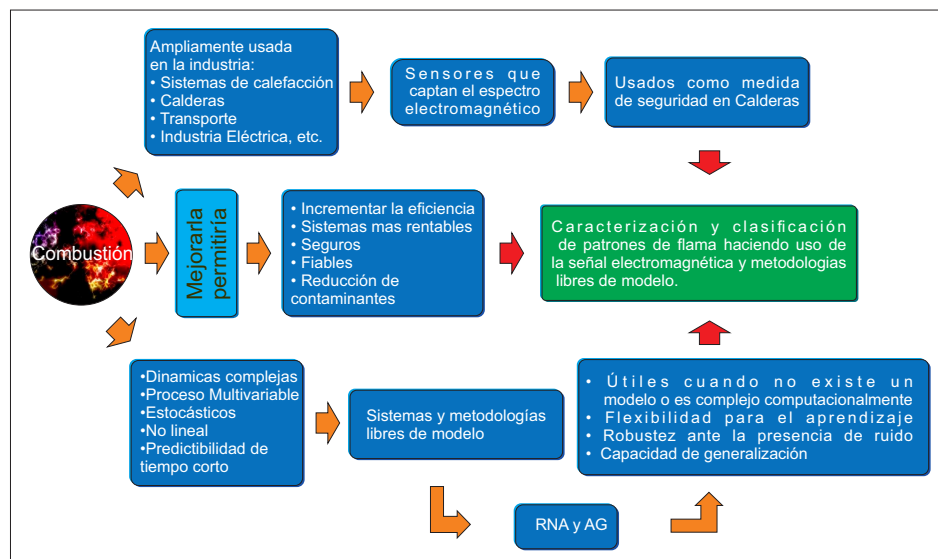


Figura 1.2: Enfoque de la problemática en la Combustión

De este modo la sinergia natural de las metodologías no deterministas tales como los Algoritmos Genéticos y las Redes Neuronales, por sus características tales como la búsqueda en espacios amplios y complejos y de generalización de conocimiento, pueden ser explotadas para producir sistemas con mayores capacidades de resolución de problemas, permitiendo su uso en sistemas complejos como la combustión y mejorando así la eficiencia de estos, a la vez que se logra un desarrollo sustentable con el medio ambiente.

Por otra parte la correlación entre la señal electromagnética y los parámetros de combustión aportaría conocimiento de gran valor y utilidad para la comprensión del fenómeno de la combustión.

1.4 Objetivo general

Diseño e implementación de un Algoritmo Genético para el entrenamiento de una Red Neuronal Artificial con la cual se caracterice el comportamiento de un proceso de combustión mediante la identificación de diferentes patrones de flama usando para ello la señal electromagnética de éstas.

1.5 Objetivos específicos

1. Identificación de los Estados de la Flama en un proceso de Combustión.
2. Procesamiento y extracción de características de la señal electromagnética.
3. Algoritmo de implementación de Redes Neuronales Artificiales.
4. Algoritmo de implementación de Algoritmos Genéticos.
5. Algoritmo de Entrenamiento de una RNA mediante Algoritmos Genéticos.
6. Validación de la RNA entrenada con señales de laboratorio.
7. Validación de la RNA entrenada con señales reales.

1.6 Hipótesis

¿ Es posible implementar un Algoritmo Genético para el entrenamiento de una Red Neuronal Artificial que tenga como entradas las características extraídas de la señal electromagnética de una flama y que sirva para la caracterización del estado de un proceso de combustión?

Capítulo 2

Marco Teórico

En este capítulo se presentan conceptos preliminares del proceso de la combustión y una revisión de las principales técnicas de monitoreo de ésta, que incluye la emisión espontánea de la radiación como patrón de flama, metodología sobre la cual se basa el desarrollo de esta tesis. Además, se muestran las metodologías de Redes Neuronales Artificiales y los Algoritmos Genéticos, así como los principales enfoques que se tienen del uso en forma conjunta de dichas metodologías.

2.1 Combustión

En los sistemas de generación de energía, se realiza una conversión controlada de la energía química del combustible a energía calorífica, que es transferida a las superficies absorbentes de calor de los generadores de vapor. Esta conversión de energía se da a través de la combustión, que se define como la liberación controlada de calor en una reacción química entre un combustible y un oxidante.

Los combustible comúnmente empleados en la generación de energía son los hidrocarburos, compuestos que contienen C, H, y/o S, tales como el gas natural y el combustóleo, mientras que el oxidante usualmente empleado es el O_2 tomado del aire, conformado en su mayoría por nitrógeno con cerca del 78% y aproximadamente del 21 % de oxígeno por unidad de volumen. En la tabla 2.1 se muestra la composición y porcentajes de los principales componentes del aire.

Tabla 2.1: Composición del aire seco

Compuesto	Peso molecular	% por peso	% por volumen
Nitrógeno	28.016	75.52	78.09
oxígeno	32.000	23.15	20.95
Argón	39.444	1.28	0.93
Dióxido de carbono	44.010	0.0035	0.03

La combinación del oxígeno presente en el aire y del carbón de los combustibles, para generar dióxido de carbón y liberar energía en forma de calor, es un proceso complejo que requiere la suficiente temperatura de activación, la correcta turbulencia en la mezcla y el tiempo suficiente para que los reactivos entren en contacto y se combinen. En la figura 2.1 se esquematiza este proceso que incluye además un diagrama Sankey del proceso en un horno en el que, una vez liberado el calor, éste sufre un proceso de degradación debido a pérdidas en los muros, aperturas, en el transporte, accesorios y equipos, y en los gases de salida, disminuyéndose considerablemente el porcentaje de calor disponible.

La combustión requiere además de un apropiado control. De otro modo, puede dar origen a la formación de altas concentraciones de productos no deseados como el Monóxido de Carbono y hollín que resultan de una mezcla pobre, mientras que otros productos como óxidos de nitrógeno se generan en forma excesiva cuando la temperatura de flama en los quemadores es demasiado alta. Si el combustible contiene azufre, puede dar origen a la formación de Dióxido de azufre gaseoso, mientras que en combustibles sólidos como el carbón y madera se forman cenizas de materiales incombustibles no quemados.

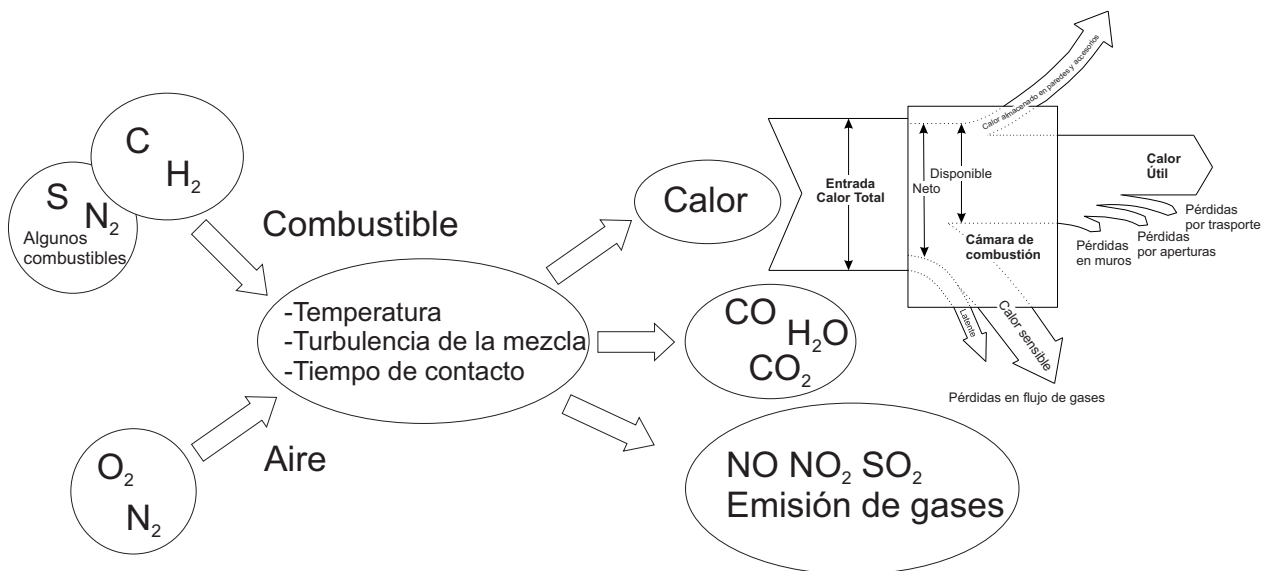


Figura 2.1: Esquema de la combustión

2.1.1 Combustión estequiométrica

Un parámetro de gran importancia que permite controlar la generación de contaminantes en la combustión es la relación aire-combustible. Bajo condiciones ideales, la combustión ocurre en proporciones exactas de combustible y aire; esta proporción teórica es llamada combustión estequiométrica. En la figura 2.2 se muestra el ejemplo de la combustión del metano, un mol de metano reacciona con 2 moles de oxígeno contenido en el aire, generando un mol de CO_2 y 2 de agua, más la liberación de energía.





Figura 2.2: Combustión estequiométrica del metano

La relación entre el aire y el combustible para una mezcla estequiométrica se calcula mediante la ecuación :

$$\frac{A}{F} = \frac{m_{\text{aire}}}{m_{\text{combustible}}} \quad (2.1)$$

Otra medida de utilidad comúnmente usada para indicar la relación aire combustible es la relación de equivalencia Φ que se define como:

$$\Phi = \frac{(A/F)_{\text{estequiométrica}}}{(A/F)} \quad (2.2)$$

Si se suministra una cantidad de oxidante mayor a la cantidad estequiométrica ($\Phi < 1$) se dice que la mezcla es pobre en combustible, mientras que si se suministra una cantidad menor de oxidante ($\Phi > 1$) se obtiene una mezcla rica en combustible. El porcentaje de exceso de oxígeno puede ser calculado usando la relación de equivalencia a través de la ecuación :

$$\% \text{ Exceso de aire} = \frac{1 - \Phi}{\Phi} 100\% \quad (2.3)$$

El exceso de aire en los sistemas de combustión es requerido para garantizar la quema del combustible y reducir la concentración de CO . Sin embargo, el exceso de aire cobra a su vez un precio, ya que al suministrar aire extra, el sistema pierde energía calorífica que es absorbida por los gases de salida, reduciendo con ello la eficiencia total. En la figura 2.3 se muestra una gráfica de las concentraciones de CO , CO_2 y O_2 con diferentes valores de exceso de oxígeno. En esta gráfica puede verse que porcentajes de oxígeno cercanos al 100% reducen la generación de CO y CO_2 ; el incremento de oxígeno garantiza la quema del combustible pero incrementa los valores de CO_2 .




Figura 2.3: Exceso de aire

2.2 Patrones de flama

La flama puede ser descrita como la zona localizada de reacción en la que la masa gaseosa incandescente producto de la oxidación emite luz y calor y se propaga de forma auto-sostenible. Una vez iniciada la reacción, ésta se propaga hacia la mezcla fresca con una velocidad subsónica llamada velocidad de propagación de la flama. Bajo ciertas condiciones, el patrón de flama puede cambiar, alargándose, disminuyendo su longitud, incrementando o disminuyendo su intensidad, etc. Estas características pueden ser típicas de la condición actual de la combustión.

2.2.1 Tipos de flamas

Las flamas o llamas en un proceso de combustión pueden ser clasificadas en función del tipo de mezcla en dos tipos: llamas de premezcla y llamas no premezcladas o de difusión. En función del tipo de movimiento del fluido, se clasifican en: turbulentas y laminares. Esta clasificación es mostrada en el Anexo C en la que se tienen ejemplos correspondientes a cada tipo.

En una flama de premezcla, el combustible y el oxidante son mezclados a nivel molecular antes de ocurrir la reacción química. Por el contrario, en una flama de difusión, los reactivos inicialmente están separados. La reacción ocurre en la interface entre el combustible y el oxidante, donde ambos, la mezcla y la reacción toman lugar. A su vez en el Anexo C se presentan las estructuras idealizadas de cada una de éstas.

Algunas de las propiedades de las flamas son:

1. **Temperatura:**

La temperatura de la flama es un valor crítico en la determinación de la transferencia de calor y es afectada por la composición del combustible, relación de equivalencia y las temperaturas del aire y combustible.

En la mayoría de los combustibles, la temperatura máxima, condición que ofrece la mayor tasa de liberación de calor, ocurre en condiciones ligeramente pobres de combustible. Esto se debe a mezclas imperfectas, por lo que se requiere mayor cantidad de O_2 , lo cual además reduce la formación de CO_2 . Un problema en la maximización de la temperatura es la formación de óxidos de nitrógeno, los cuales se incrementan exponencialmente con el incremento de la temperatura [2].

2. **Energía mínima de inflamación:**

Es la energía mínima que se aporta a una mezcla estequiométrica para que tenga lugar la combustión. La temperatura a la que se alcanza es llamada temperatura de inflamación o de ignición y el tiempo en el que se da la ignición una vez alcanzada ésta es llamado retardo de ignición.

La temperatura de ignición depende de parámetros como la relación aire combustible y la presión de la cámara de combustión. Otro parámetro de importancia es la temperatura de auto-inflamación, valor en el cual una mezcla se enciende en ausencia de una chispa o llama.

3. **Límites de inflamación**

Corresponde a los límites dentro de los cuales la relación aire combustible es apta para la combustión. No todos los combustibles tienen el mismo límite de inflamación. El límite inferior hace referencia a la condición en la que existe el suficiente combustible (mezcla pobre) para alcanzar la mínima energía de ignición, mientras que en el límite superior no existe el suficiente oxígeno (mezcla rica). El límite de inflamación puede calcularse mediante la regla de Le Chatelier [37]:

$$L_m = \frac{1}{\sum \frac{X_j}{L_j}} \quad (2.4)$$

donde X_j es la fracción molar (o el volumen) del componente j , L_i su límite de inflamabilidad (inferior o superior) y L_m el límite (superior o inferior) de la mezcla.

4. **Velocidad:**

La velocidad de la reacción hace referencia a qué tan rápido se quema la mezcla. Esta medida es de gran importancia en la estabilización de las flamas y en la determinación de la tasa de

liberación de calor. La velocidad es afectada por la temperatura de la flama, propiedades del combustible como viscosidad y conductividad térmica y por parámetros como la relación aire combustible, presión, temperatura del aire y del combustible y turbulencia de la flama. Cuando el suministro de combustible es mayor que la velocidad de flama, ésta puede desplazarse separándose del quemador (*lift-off*). Por el contrario, si el suministro de combustible es menor, se presentará un retroceso en la flama (*burnback*).

La velocidad de la flama laminar S_L está en función de la cinética de la reacción de combustión, existiendo varios métodos para su determinación, como el de Zeldovich, Frank-kamenestkii, Semenov y el modelo de Mallard-Le Chatellierd. Este último está descrito por la ecuación (2.5) en la que se establece que el calor necesario para alcanzar la temperatura de ignición T_i entre la zona 1 y 2 (ver figura 2.4) está dado por la zona 2.

$$\dot{m} = c_p(T_i - T_o) = k \frac{T_f - T_i}{\delta} A \quad (2.5)$$

Donde $\dot{m} = \rho A u_L = \rho S_L A$

Debido a que la velocidad de los gases no quemados $u_L = S_L$ se trata de un régimen estacionario se deduce que

$$\delta \approx \frac{\alpha}{u_L} \quad (2.6)$$

Siendo α la difusividad térmica $\frac{k}{\rho C_p}$.

El análisis de la velocidad de las flamas turbulentas por su parte aún sigue siendo objeto de estudio.

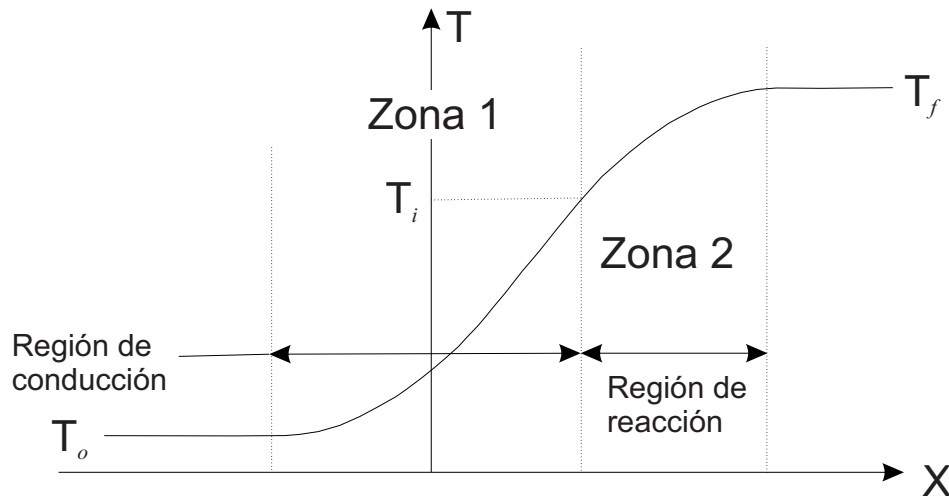


Figura 2.4: Modelo de Mallard-Le Chatellierd

2.3 Radiación electromagnética

La radiación electromagnética es una forma de transmisión de la energía. Como su nombre lo indica, la radiación electromagnética está constituida por campos eléctricos y magnéticos mutuamente perpendiculares que oscilan en ondas senoidales en fase sobre planos individuales. La radiación electromagnética puede ser caracterizada por su dirección, velocidad de propagación, longitud de onda o frecuencia, el estado de polarización y la cantidad de energía [46]. En la figura 2.5 se pueden observar las regiones del espectro electromagnético en función de algunos de estos parámetros.

La velocidad de la radiación en el espacio vacío es igual a la velocidad de la luz, $c = 2.99776 \times 10^{10}$ cm/seg. La velocidad en otro medio es determinado por el índice de refracción del medio:

$$v = c/n \quad (2.7)$$

La radiación electromagnética caracterizada en función de su longitud de onda λ en el aire o vacío, número de onda ν o frecuencia ν ambas convencionalmente en el vacío, está dada por la relación:

$$\lambda_{vac} = \frac{c}{\nu} = \frac{1}{\tilde{\nu}} \quad (2.8)$$

Cuando la radiación interactúa con la material, un cuanto de energía (o fotón) puede ser partícipe de diferentes procesos incluyendo reflexión, dispersión, absorción, fluorescencia/fotofluorescencia y reacciones fotoquímicas. La energía del cuanto está relacionada con la frecuencia a través de la ecuación:

$$\Delta E = h\nu \quad (2.9)$$

donde $h = 6.626 \times 10^{-34}$ Js es la constante de Planck.

2.3.1 Espectroscopía

El espectro electromagnético emitido por los objetos provee información sobre la composición elemental y abundancia relativa de los elementos así como características físico-químicas mediante la división de la luz emitida en sus componentes de color. Cada uno de estos colores es indicativo de una transición atómica específica, proporcionando información sobre la identidad de los compuestos en particular. Todos los elementos y compuestos tienen una única firma espectral. La espectroscopía estudia esta relación entre la radiación magnética y la materia.

Uno de los dispositivos empleados para la medición de la radiación electromagnética es el espectroscopio que separa la radiación en sus frecuencias constituyentes y permite una inspección visual. Un espectrómetro, por su parte, permite la medición de la frecuencia y si éste además, provee una medición de la cantidad relativa de energía asociada a la longitud de onda, es llamado espectrofotómetro. Estos dispositivos convierten la señal de la luz en una señal eléctrica. Idealmente, deben proporcionar una respuesta sobre un amplio rango con un bajo nivel de ruido y una alta sensibilidad.

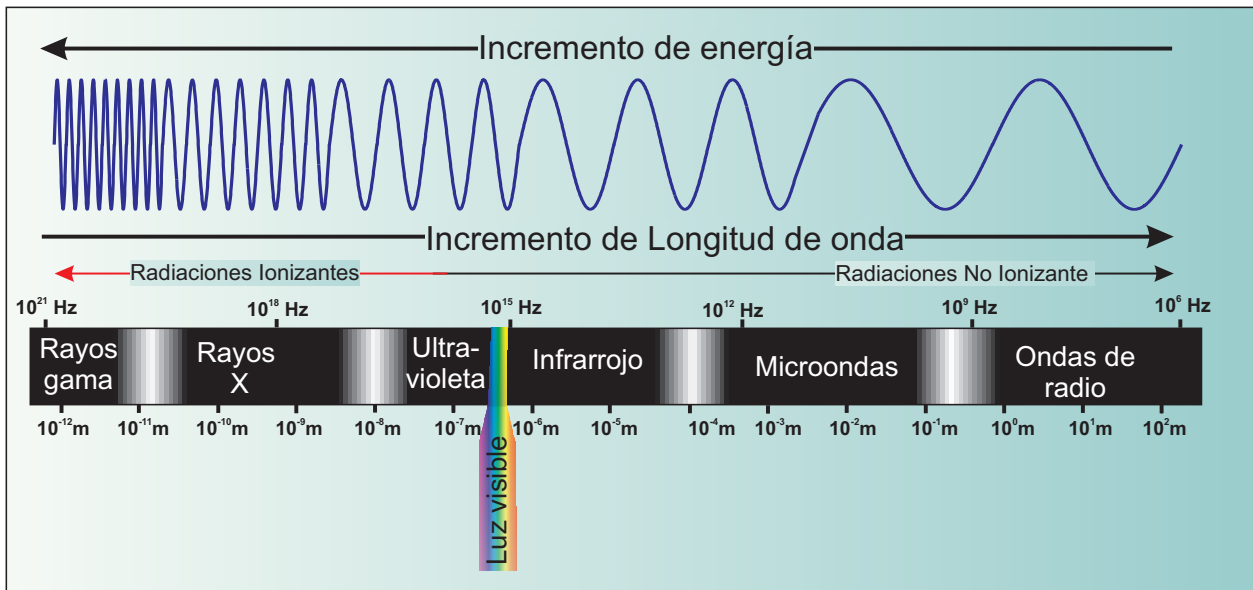


Figura 2.5: Regiones del espectro electromagnético. La luz visible, ultravioleta e infrarroja se origina de la transición en los átomos. Los rayos gama se originan de eventos similares en los núcleos de los átomos. Los rayos x pueden formarse de diferentes formas pero comúnmente se forma de la aceleración rápida de los átomos. En el otro lado del espectro, las ondas de radio resultan de la oscilación de grandes cantidades de partículas cargadas.

Además de estos mecanismos de medición, en la espectroscopía se emplean también dispositivos denominados detectores de radiación que permiten registrar propiedades de los campos de radiación tales como su intensidad o energía.

Los detectores de radiación pueden ser divididos en detectores de radiación ionizante y radiación no ionizante. Ejemplos de detectores de radiación ionizante son las cámaras de ionización, placas radiográficas, contador Geiger y detectores de burbujas. En aplicaciones industriales los detectores se basan generalmente en la detección de la radiación no ionizante, más específicamente en el espectro ultravioleta (UV), visible e infrarrojo (IR) y combinaciones de éstos.

Los detectores de señales electromagnéticas no ionizantes están conformados por elementos fotoeléctricos que detectan el rango espectral con transductores como fotodiodos, fotoceldas, foto-transistores o fotorresistencias y proveen una señal eléctrica proporcional a la fuente de luz a la que son expuestos. Las señales del sensor en sistemas comerciales se basa en diversas técnicas para determinar la condición de la flama tales como el análisis del parpadeo de la frecuencia, comparación de la señal de energía con un umbral, análisis de correlación entre diferentes señales, técnicas de comparación con compuertas lógicas y correlación con análisis de bases de datos.

En los procesos de combustión en hornos los principales contribuyentes a la radiación de las flamas son el CO_2 , H_2O , el hollín y las cenizas, mientras que diversas fuentes de ruido en la señal de radiación pueden ser originadas por la refracción del horno y quemadores adyacentes. Por ello, los sistemas de detección deben ser capaces de distinguir entre la señal de la flama a medir y la

radiación espuria generada en la cámara de combustión. Los dispositivos comerciales toman la señal proveniente del dispositivo y la procesan previendo una salida que bajo un umbral establecido indica la presencia o ausencia de flama.

2.4 Monitoreo de la combustión

Los sistemas de monitoreo de flamas tiene como objetivo recolectar información directamente de la flama a través de la cual se pueda determinar su estado y poder realizar un control sobre el proceso de la combustión de modo que se optimice el proceso, mejore el consumo de combustible, reduzca la emisión de gases contaminantes y mejore la seguridad y confiabilidad de los equipos de combustión. En la actualidad, el monitoreo de la combustión está principalmente basado en el análisis de los gases de salida y parámetros del proceso de combustión.

El análisis del proceso de combustión a través del estudio de la flama permite tener un análisis más adecuado del proceso actual de la combustión. Diversos métodos de monitoreo y seguimiento del estado de la combustión a través del análisis de la flama se han desarrollado, algunos de los cuales han sido estudiados y desarrollados en laboratorios sin haber sido llevados a la práctica en aplicaciones industriales. Los métodos de monitoreo de la combustión actuales pueden ser clasificados en 3 grupos en función de los tipos de sensores empleados:

1. Electroscopía de las flamas (sensores ópticos)
2. Técnicas mediante imágenes
3. Transductores de presión

2.4.1 Electroscopía de las flamas

Como se menciona en la sección 2.3.1, esta metodología se basa en la medición de la luz emitida o absorbida por la flama. El principal enfoque se basa en la medición de la radiación espontánea emitida por cuerpos sólidos tales como el hollín, cenizas o inquemados, radiación producto de los gases de combustión y la radiación emitida debido a algunas reacciones químicas. Los rangos del espectro de cada una de estos varían dentro del espectro electromagnético desde el ultravioleta hasta el infrarrojo pasando por el rango visible, dependiendo de las características de la flama. En la figura 2.6 se presenta a manera de ejemplo la intensidad de radiación relativa de diferentes combustibles. Como se observa, cada tipo de combustible presenta un comportamiento característico que puede ser usado como una firma que lo identifica.

La electroscopía a través del análisis de la flama, se puede realizar a su vez a través del análisis de la radiación emitida por reacciones químicas. A esto se le denomina quimioluminiscencia, siendo los principales contribuyentes en la radiación de las flamas en hornos de combustión el CO_2 y H_2O . Otra perspectiva más general es considerar el espectro de luz emitido por una flama como una firma

distintiva de ésta, sin considerar bandas espectrales características. Otro enfoque se basa de la medición de la composición de los gases, basado en la atenuación de un haz de luz a través de una muestra de gas a longitudes de onda específicas que son característicos de los diferentes compuestos químicos [1]. A continuación se realiza una descripción de las características más relevantes de estas metodologías.

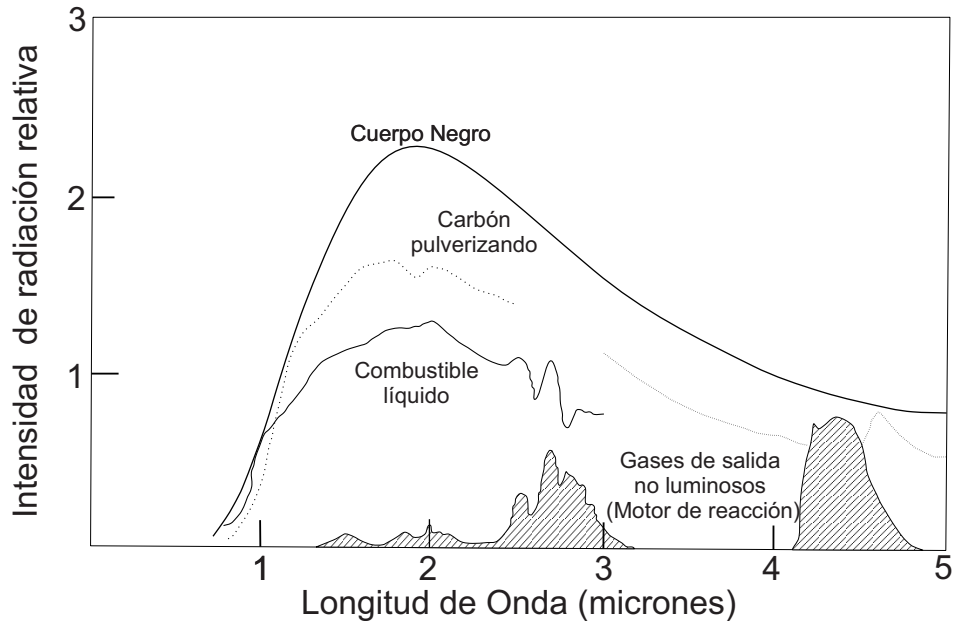


Figura 2.6: Intensidad de radiación de diferentes combustibles [40].

2.4.1.1 Quimioluminiscencia

La quimioluminiscencia es el principio básico de muchos detectores de flama que verifican la presencia de flama colectando la radiación en un cierto rango del espectro electromagnético y comparándolo con un umbral definido. La quimioluminiscencia ocurre en los rangos UV (190-380 nm) y visible (380-750 nm).

La formación de radicales se produce debido a la excitación térmica y reacciones químicas originadas principalmente en la zona de reacción cercana a las boquillas de los quemadores. La quimioluminiscencia incluye dos etapas; la primera es la formación del radical excitado y la segunda es la pérdida espontánea del exceso de energía a través de la emisión de fotones, siendo la luz emitida proporcional a la concentración del radical excitado. La emisión de radiación en ciertas longitudes de onda puede ser asociada con determinados radicales, que a su vez pueden estar relacionados con condiciones específicas de la combustión, tales como una combustión pobre o rica en combustible, pérdida de calor o estabilidad [23, 31, 38, 39].

Una aplicación directa de la quimioluminiscencia es la detección de la flama a través de la comparación de la radiación recolectada con un umbral que define la presencia o no de la flama,

así como la medición de la tasa de liberación de calor. Otros enfoques comunes de la quimioluminiscencia se basan en el cálculo de la proporción entre dos bandas de quimioluminiscencia, por ejemplo OH^*/CH^* , CH^*/C_2^* [23, 41], haciendo más estable la medición a fluctuaciones en la tasa de liberación de calor y turbulencias de la flama.

2.4.1.2 Espectroscopía de absorción láser

La espectroscopía láser se basa en la atenuación de un haz de láser que está definida de acuerdo con la ley de Beer-Lambert.

$$I_v = I_{v,0} \exp[-S(T)g(v - v_0)Nl]Tr(T) + E(t) \quad (2.10)$$

Donde I es la intensidad monocromática del láser a la frecuencia v , medida antes ($I_{v,0}$) y después (I_v) de propagarse una longitud l a través de un medio absorbente con una densidad N . La atenuación depende de la sección transversal de absorción, calculada como el producto de la línea de temperatura $S(T)$ y la línea de forma $g(v - v_0)$. A su vez, son incluidas las perturbaciones térmicas tales como radiación de fondo de las partículas o paredes de la cámara de combustión $E(t)$ y efectos adicionales de absorción $Tr(t)$ originados por partículas de polvo o cenizas.

Esta técnica puede ser adaptada para la medición de la concentración de componentes [10], flujo [21], temperatura, velocidad y presión [29, 53]. Algunas de las sustancias que pueden ser medidas con esta técnica son el O_2 , CO_2 , vapor de agua y algunos hidrocarburos. Otros enfoques también incluyen el análisis de la distribución del tiempo de residencia en regiones de altas temperaturas y medición de concentraciones y temperaturas en combustores a presión [51].

En la figura 2.7 se muestra el diagrama del uso de la técnica de espectroscopía de absorción con láser de diodo sintonizable (TDLAS: Tunable Diode Laser Spectroscopy) [15, 16] para la detección de gases.

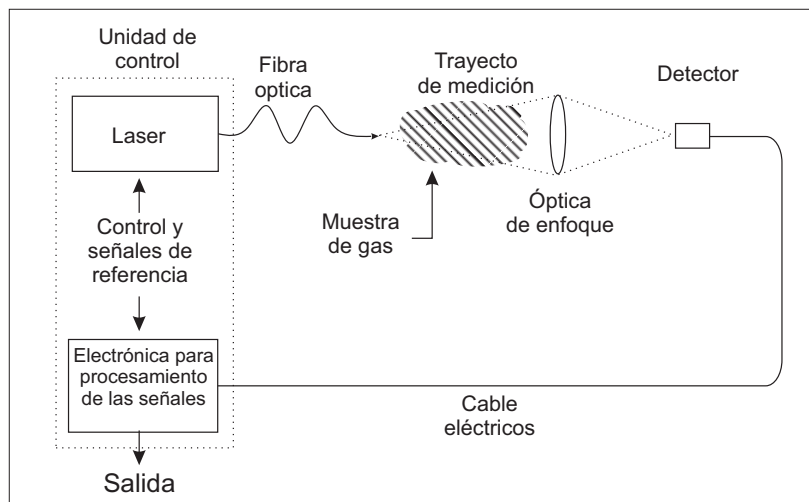


Figura 2.7: Sistema de detección de gases mediante TDLA[15].

2.4.1.3 Emisión espontánea como patrón de flama

Este enfoque trata de hallar una correlación entre la señal óptica obtenida y parámetros de la combustión, tales como el estado estequiométrico de la combustión, la emisión de gases contaminantes, propiedades del combustible, o condiciones de operación [17, 42, 45], siendo para ello necesario el procesamiento de la señal extrayendo ciertas características y parámetros como el promedio del señal, la desviación estándar, y características relacionadas a la frecuencia, entre otras.

Mediante esta perspectiva es necesario el establecimiento de una relación entre las características obtenidas de la señal y los patrones de la combustión que pueda ser representada a través de algún modelo que sirva para la estimación de los parámetros de la combustión a partir de dichas características de la señal. La determinación del modelo en la mayoría de los casos es compleja de establecer debido a la naturaleza multivariable, altamente no lineal y estocástica de la combustión. Técnicas y metodologías libres de modelo como las Redes Neuronales Artificiales (RNA) y algunas otras como la Lógica Difusa, Sistemas Expertos y Algoritmos Genéticos (GA) han sido empleados en aras de determinar dicha relación.

Para la extracción de las características, la emisión de radiación puede ser captada mediante diversos métodos que incluyen detectores con configuraciones de sensores integrados con capacidad de detección del espectro dentro del rango UV, Visible e IR. Dispositivos más avanzados ofrecen sensores IR con triples longitudes de onda.

Detectores de IR:

Estos detectores consisten de sistemas que capturan el espectro IR generado por la flama y los productos de la combustión (.75-1000 micrómetros). Pueden responder al parpadeo de las flamas en un rango de frecuencia de 5 a 50 Hz. Este parpadeo está presente en diferentes magnitudes y frecuencias en todos los cuerpos radiantes dentro de la cámara de combustión, permitiendo ser usada para discriminar la radiación de fuentes de ruido. Algunos de los materiales empleados como celdas fotoconductoras y fotovoltaicas en detectores IR son el sulfuro de plomo (PbS), seleniuro de plomo (PbSe), el antimonio de indio (InSb), el Germanio (Ge), y aleaciones de mercurio telurio de cadmio (HgCdTe) y Arseniuro de galio-indio (InGaAs).

Detectores de Radiación Visible:

Los detectores de radiación visible (360-830nm) son de dos tipos, formados por fotoceldas de transductores de sulfuro de cadmio y óxido de zinc. Su aplicación está limitada a quemadores de combustibles fósiles al requerir de flamas luminosas.

Detectores UV:

Los detectores de UV cercano detectan emisiones producidas por el proceso de ionización (180-260 nanómetros). Las emisiones UV son producidas por la ionización que forma parte de la oxidación del combustible en una flama. En la etapa temprana de la combustión, el área de la flama cercana a la boquilla, es la zona de mayor generación de radiación UV.//

Los detectores UV están constituidos por electrodos metálicos puros envueltos en gas inerte al alto vacío. Al ánodo del sistema se le aplica un diferencial de potencial y cuando los fotones UV en cantidad suficiente golpean el cátodo, un electrón se libera desde el electrodo y es atraído hacia el ánodo. En su movimiento, este electrón colisiona con una molécula de gas y desplaza otro electrón, que a su vez choca con dos moléculas y desaloja dos electrones más, produciendo una “avalancha” que permite un flujo de corriente.

Uno de los retos al buscar relacionar la señal obtenida del espectro con la combustión es poder realizar la correcta selección de las características que estén significativamente correlacionadas con algún parámetro en particular de la flama.

2.4.2 Técnicas mediante imágenes

Diversas técnicas de monitoreo basadas en imágenes han sido aplicadas a la combustión [1]. Éstas se basan en el uso de cámaras CCD, cámaras termográficas y cámaras de vídeo a través de las cuales se obtienen imágenes que proveen información del estado de la flama.

El uso de métodos de visión puede ser usado en conjunto con la quimioluminiscencia para determinar la presencia de radicales, y, en conjunto, con técnicas de pirometría para el cálculo de la temperatura de las partículas y gases.

En algunas aplicaciones particulares la información obtenida de las imágenes puede, por sí misma proveer información suficiente para caracterizar una flama; por ejemplo distribuciones de temperatura o la longitud de la flama. Sin embargo, en la mayoría de los casos, esto no es posible, se requiere una etapa de procesamiento e interpretación en la que se correlacionan los datos con parámetros de la combustión que pueden basarse en la extracción de características del color y su distribución, luminosidad, geometría, características de la forma de la flama o en el análisis del color en conjunto con el parpadeo de la flama (movimiento de la flama) [6, 49, 50], relacionándolas a su vez con emisiones de NO_x , partículas inquemadas, radicales de OH^* , CH^* , CO_2^* , perfiles de temperatura, etc. En la figura 2.8 se muestra el diagrama conceptual de monitoreo de la combustión mediante este enfoque.

A su vez, también se han usado técnicas como la reconstrucción tomográfica y estereoscópica para la obtención de distribuciones de luminosidad y para describir estructuras tridimensionales [8, 35]. Otro enfoque diferente consiste en considerar la imagen como el conjunto de datos que pueden ser procesadas como un todo y que representan una firma particular de un estado de la combustión [1]. Además, el uso de algoritmos de reconocimiento de patrones, tales como Mapas Autorregulados y Redes Neuronales [3, 47, 48] ha mostrado ser útiles en la identificación de parámetros de la combustión en correlación con el aspecto de las flamas.

Algunas de las dificultades adicionales, además de las propias relacionadas con las técnicas de

tratamiento de imágenes, son la instalación del hardware y la protección del mismo a las altas temperaturas presentes en las cámaras de combustión así como el poder de cómputo requerido para procesar la cantidad de información que proveen los sensores. Sin embargo, los estudios realizados en el área muestran que la información obtenida a través de estas metodologías está íntimamente correlacionada con las propiedades de las flamas.

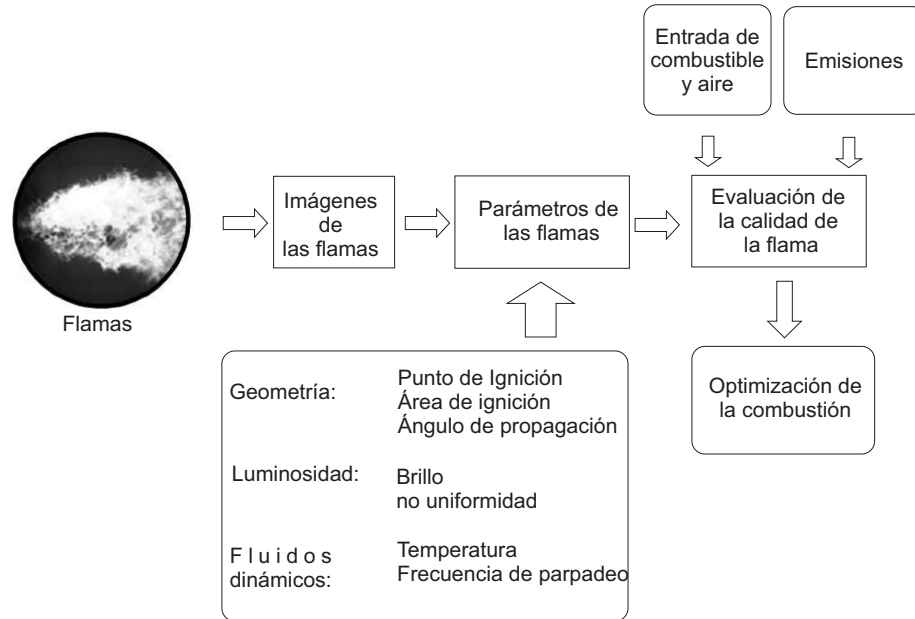


Figura 2.8: Diagrama conceptual del monitoreo mediante imágenes [34].

2.4.3 Transductores de presión

Se generan fluctuaciones de presión en la combustión debido, principalmente, a las fluctuaciones de liberación de calor, causando la repentina expansión de fluidos. Estas fluctuaciones producen ruidos que son usualmente más altos que los correspondientes a flujos isotérmicos. Algunos de estos cambios inestables de liberación de calor son producidos por turbulencias en las flamas, efecto denominado “rugido de la combustión”, desprendimiento de vórtices y precesión de vórtices.

Bajo ciertas suposiciones, la ecuación de la onda de presión en un flujo de combustión está definida por [26]:

$$\Delta^2 p' = -\frac{1}{c^2} \frac{\delta^2 p'}{\delta t^2} = -\frac{1}{c^2} \frac{\delta}{\delta t} [(\gamma - 1) \dot{Q}'] \quad (2.11)$$

La principal motivación del estudio de los cambios de presión es el estudio de la detección, caracterización y corrección de las inestabilidades en la combustión. Para su estudio, los principales instrumentos de medición son micrófonos y traductores de respuesta rápida que miden las fluctuaciones de presión.

2.5 Pre-procesamiento de señales

El pre-procesamiento en reconocimiento de patrones es la etapa en la que se tratan los datos en crudo de forma que puedan ser usados en el sistema de clasificación. Éstos pueden incluir el filtrado, suavización, normalización de los datos y la extracción y selección de características.

Así por ejemplo, el filtrado es usado para la eliminación de ruido y la suavización para mejoramiento de la señal. La normalización pretende evitar problemas de escalamiento en los datos. Un parámetro con una menor escala contribuiría menos en la distancia total de un vector de características, mientras que la extracción de características pretende buscar parámetros que describan un sistema y que sean invariantes a transformaciones irrelevantes. En algunos casos, la extracción de estas características a su vez permite establecer una relación intrínseca con los parámetros del problema en cuestión.

Una de las formas de pre-procesamiento más importantes es la reducción de dimensión de los datos de entrada. Algunas técnicas que pueden ser usadas con este fin son el Análisis de Componentes Principales (PCA: Principal Component Analysis), Análisis de Componentes Independientes (ICA: Independent Component Analysis), Análisis Lineal Discriminante (LDA: Linear Discriminant Analysis) y Escalado Multidimensional (MDS: Multidimensional Scaling). La reducción de dimensión permite el uso de menos datos de entrada en un sistema de clasificación. De esta forma, por ejemplo en el empleo de Redes Neuronales, una arquitectura con menos entradas será más rápida de entrenar. En la mayoría de los casos esta reducción de dimensionalidad representa pérdida de información, siendo el objetivo preservar la información más relevante posible.

El resultado obtenido en un problema de clasificación de patrones está fuertemente ligado a la selección correcta de las características que representen en mejor medida la dinámica del problema. Un sistema ideal de extracción de características supondría la tarea del reconocimiento de patrones como trivial, mientras que un sistema de reconocimiento de patrones ideal no requeriría la extracción de características como etapa previa.

2.6 Redes Neuronales Artificiales

Las Redes Neuronales Artificiales (RNAs) son metodologías inspiradas en el funcionamiento del cerebro humano que tratan de emular la forma en la que las neuronas almacenan y procesan la información. De esta forma las redes neuronales se asemejan al cerebro humano en la adquisición del conocimiento mediante un proceso de aprendizaje y lo almacenan a través de conexiones interneuronales llamados pesos que hacen referencia a las conexiones sinápticas de las neuronas biológicas.

Kohonen [28] define a las Redes Neuronales como un conjunto de elementos de cálculo simples, usualmente adaptativos, interconectados masivamente en paralelo, que tiene una organización jerárquica que les permite interactuar con algún sistema del mismo modo que lo hace el sistema nervioso biológico.

Así mismo, se ha descrito a un RNA como una representación esquemática de un modelo matemático formado por unidades procesadoras interconectadas que recibe valores que son llamados entradas y proporciona valores denominados salidas. Estos sistemas tienen la capacidad de reconocer y asociar patrones y pueden ser aplicadas a problemas lineales y no lineales.

Gracias a ventajas tales como la capacidad de generalización, tolerancia al ruido y a la disponibilidad de diferentes modelos de aprendizaje, las RNAs han sido empleadas exitosamente en diversas áreas como la robótica y sistemas de control, reconocimiento de patrones y clasificación, compresión de datos, regresiones no lineales, finanzas, medicina, entre otras. Debido a su diseño, estas metodologías son particularmente útiles en problemas en los que no se cuenta con un modelo matemático definido, o cuando éste es muy complejo u obtenerlo implica un costo computacional muy alto.

En la figura 2.9(a) se presenta la estructura básica de una neurona, constituida por una entrada P , el peso de la conexión w , y la función de transferencia o de activación f . Por su parte, en la figura 2.9(b) se tiene el esquema de una neurona con múltiples entradas. Este modelo básico representa al esquema del perceptrón estudiado por Rosenblatt [43], donde la función de activación corresponde a una función Harlim (ver sección 2.6.1). La salida de la neurona es calculada mediante la evaluación de n con la función de activación, donde n se obtiene de la multiplicación de la entrada con el peso más el umbral o sesgo b .

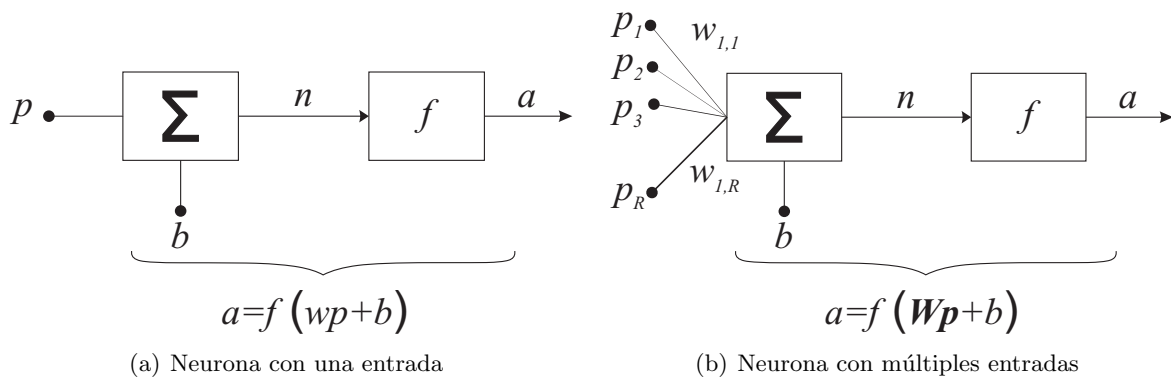


Figura 2.9: Esquemas de una neurona.

Una red neuronal se caracteriza por tres elementos fundamentales:

1. Topología de la red
2. Tipo de entrenamiento
3. Regla de aprendizaje

La exitosa aplicación de las RNA en el modelado de problemas está influenciada principalmente por tres factores : La arquitectura de la RNA, el tipo de función de activación y el tipo de entre-

namiento [13]. De este modo, diferentes tipos de arquitecturas pueden tener un desempeño similar y arquitecturas semejantes pueden tener desempeños completamente diferentes.

2.6.1 Topología de una RNA

La topología o arquitectura de un RNA representa la estructura de la red, es decir, la forma y organización de las interconexiones de las neuronas, las capas en las que se organiza y las funciones de transferencia empleadas.

Las principales funciones de transferencia empleadas en las RNAs se presentan en la figura 2.10










Nombre	Relación Entrada/salida	Icono
Hard Limit	$a = 0 \quad n < 0$ $a = 1 \quad n \geq 0$	
Hard Limit Simétrico	$a = -1 \quad n < 0$ $a = +1 \quad n \geq 0$	
Lineal	$a = n$	
Saturación Lineal	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n \leq 1$ $a = 1 \quad n > 1$	
Saturación Lineal Simétrica	$a = -1 \quad n < -1$ $a = n \quad -1 \leq n \leq 1$ $a = 1 \quad n > 1$	
Sigmoidal	$a = \frac{1}{1 + e^{-n}}$	
Tangencial hiperbólica	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
lineal Positiva	$a = 0 \quad n < 0$ $a = n \quad 0 \leq n$	
Competitiva	$a = 1$ Neurona con el máximo n $a = 0$ Todas las demás	

Figura 2.10: Funciones de transferencia.

Existen diferentes modelos de Redes Neuronales entre los que destacan los siguientes Perceptrón (1957), Adaline y Madaline (1960), Avalancha (1967), Retropropagación (1974), Hopfield y mapas auto-organizados (1980), Teoría de la Resonancia Adaptativa (1986). Una de las arquitecturas más empleadas es el perceptrón multicapa, que es presentado en la figura 2.11.

A su vez, las Redes Neuronales se dividen en función del manejo del flujo de la información en: unidireccional, si todas las conexiones son de un nodo a otro de forma que no se pueden trazar ciclos, y en redes recurrentes si las conexiones entre los nodos pueden generar ciclos.

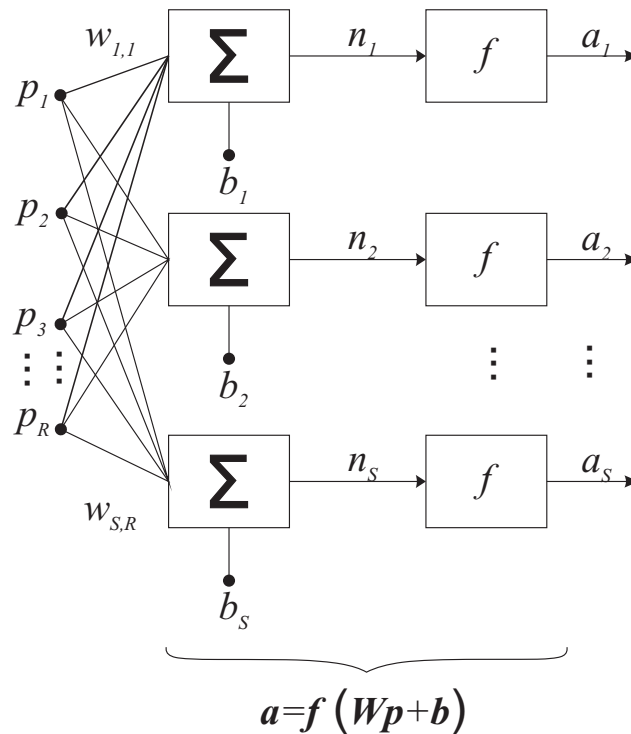


Figura 2.11: Red neuronal perceptrón multicapa.

2.6.2 Tipo de Entrenamiento

La etapa de aprendizaje o entrenamiento es el proceso de ajuste de los parámetros de la Red Neuronal a través de la estipulación mediante la presentación iterada de patrones. Se divide básicamente en dos tipos:

1. Entrenamiento supervisado
2. Entrenamiento no supervisado

El primero corresponde a la presentación de patrones de entrenamiento de los cuales se sabe el valor de salida que debe mostrar la RNA. De esta forma, el entrenamiento consiste en comparar el valor obtenido de la salida de la RNA y el valor esperado, haciéndose una modificación a los pesos en función del error obtenido y de alguna regla de aprendizaje.

En el segundo tipo de entrenamiento no se conoce la salida deseada de los patrones y el entrenamiento se realiza mediante la correlación existente entre los patrones. La mayoría de estos algoritmos realizan algún tipo de operación de agrupamiento.

2.6.3 Regla de Aprendizaje

La regla de Aprendizaje o de Entrenamiento de una RNA determinan los cambios que se realizan en los pesos de las conexiones al presentarse nuevos patrones. Algunos ejemplos incluyen el aprendizaje Delta, el aprendizaje Hebbiano, el Anti-Hebbiano o Reglas de Aprendizaje Competitivas y

Retropropagación [13].

Un factor de gran importancia a considerar en la etapa de entrenamiento es el grado de generalización hacia nuevos patrones. Un entrenamiento pobre no permitirá clasificar correctamente los patrones debido a la débil conexión de los pesos, mientras que un entrenamiento excesivo originará que la RNA pierda su capacidad de generalización aprendiendo únicamente los patrones que sirvieron de entrenamiento; este último caso es llamado comúnmente sobreentrenamiento.

La selección general de la arquitectura en una RNA está en función del modelo y características de éste, pudiéndose emplear diferentes arquitecturas para la solución de un problema. Sin embargo, la selección correcta de los parámetros de cada una de las arquitecturas está en función del grado de conocimiento que se tiene sobre dicha arquitectura. En la mayoría de los casos, parámetros tales como número de neuronas, factores de aprendizaje, funciones de transferencia, etc., son ajustados mediante prueba y error.

2.6.4 Retropropagación

Es el tipo de entrenamiento más empleado. Consiste en un algoritmo de optimización de primer orden que trata de minimizar el error cuadrático medio entre la salida actual y el valor objetivo de la RNA. Este algoritmo está basado en el método de Gradiente descendente.

Durante la propagación hacia adelante, las señales de entrada son tratadas de la capa de entrada a las capas ocultas y de ahí a la capa de salida. El estado de las neuronas sólo afecta a las neuronas en la siguiente capa. El valor del error es entonces propagado hacia atrás a través de la neurona y se hacen cambios en los pesos de cada capa. El cambio de los pesos es calculado para reducir el error de la señal para el caso en cuestión. El ciclo es repetido hasta que el error cae bajo un cierto valor establecido.

Algunos inconvenientes que tiene este algoritmo es que puede quedar atrapado en mínimos locales de la función de error. Adicionalmente, es ineficiente en la búsqueda de mínimos globales de funciones multimodales, además de requerir funciones de transferencia diferenciables.

Una forma de superar las deficiencias es considerar el proceso de entrenamiento como una evolución de los pesos de las conexiones hacia un conjunto óptimo (o cercano al óptimo) definido por una función de aptitud u objetivo (fitness function) y hacer que el entrenamiento sea el medio ambiente en el cual ocurre la evolución [56]. La idea principal es usar los sistemas evolutivos como una función optimizadora para maximizar la función de desempeño, minimizando las funciones de error.

2.7 Algoritmo Genético

Los Algoritmos Genéticos surgieron como una aproximación que buscaba imitar los procesos evolutivos y su implementación en sistemas computacionales. Algunas de las primeras ideas que hacen alusión a sistemas evolutivos fueron desarrolladas por Fraser [14] y Bremermann [4]. En 1975 surgió por primera vez el término Algoritmos Genéticos en el libro “Adaptation in natural and artificial systems” escrito por Holland [24]. Las ideas desarrolladas por Holland y sus colegas en la universidad de Michigan surgieron inicialmente como un enfoque al estudio de la adaptación como ocurren en la naturaleza y su desarrollo para la implementación en procesos lógicos.

Los Algoritmos Genéticos son métodos de búsqueda que imitan los principios básicos de la vida inspirados en la Teoría de la evolución de Darwin en los que se aplican operadores genéticos como la mutación, cruzamiento o selección a una secuencia de alelos, creando nuevos descendientes con propiedades heredadas de sus padres.

Por su parte, Koza [30] define a los Algoritmos Genéticos como:

“Un modelo matemático altamente paralelo en el que un conjunto de objetos matemáticos individuales, típicamente cadenas de caracteres fijos que simulan cadenas de cromosomas con una función asociada que refleja su aptitud, son transformados hacia una nueva población usando operaciones basadas en los principios darwinianos de la reproducción y la supervivencia del más apto y tras haber ocurrido de forma natural operaciones genéticas.”

En la figura 2.12 se muestra el esquema general de un Algoritmo Genético, el cual parte de un conjunto de individuos (población inicial) representados como cadenas de caracteres llamados cromosomas, que son tomados del espacio de búsqueda en forma aleatoria y evaluados mediante una función que les asigna un valor o grado de adaptación (función de adaptación Sec. 2.7.1). Mediante este valor se seleccionan los individuos que han de ser combinados (cruza), permitiendo a los mejores individuos una mayor probabilidad de transmitir sus características a la siguiente población.

Los Algoritmos Genéticos y evolutivos pueden ser usados ventajosamente en muchos problemas de optimización. Algunas de las aplicaciones de los Algoritmos Genéticos incluyen su uso en espacios grandes y complejos, problemas en los que no se tiene un gradiente de conocimiento y en espacios con funciones multimodales.

El principio de funcionamiento de los Algoritmos Genéticos continúa siendo un tema de debate, siendo ampliamente reconocidos como fundamentos el Teorema de los Esquemas (Sección 2.7.6) descrito por Holland y la hipótesis los Bloques Constructores (Sección 2.7.7) descrita por Goldberg [18].

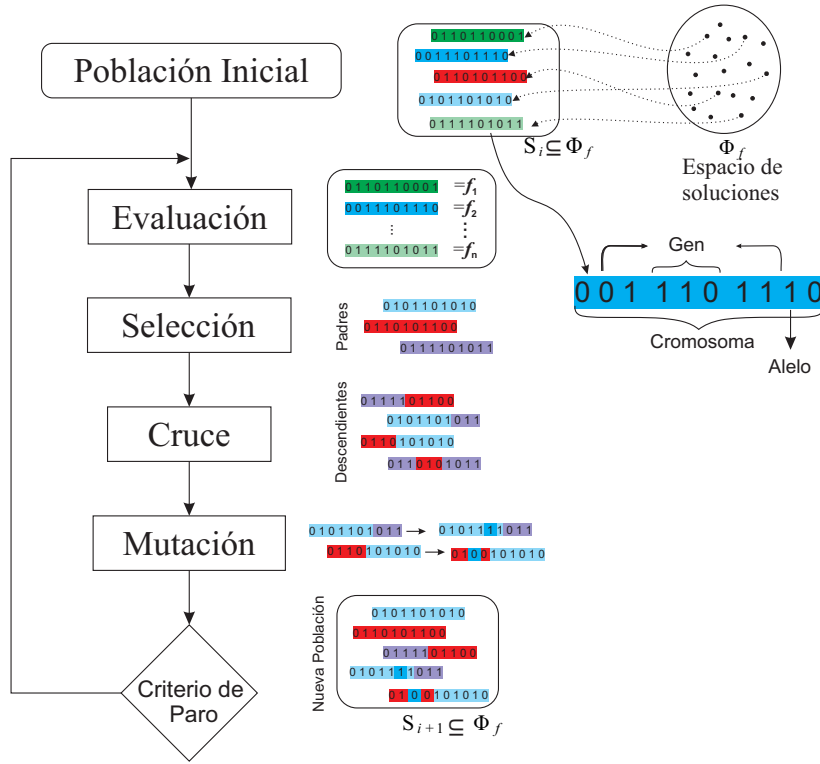


Figura 2.12: Esquema general de un Algoritmo Genético.

2.7.1 Representación

Una parte fundamental en los Algoritmos Genéticos es el uso de una representación de las posibles soluciones a un problema las cuales son transformadas a un nuevo espacio en el que es posible aplicar operadores no aritméticos que permiten combinar las mejores soluciones halladas y explorar a su vez nuevas regiones del espacio. Esta representación se define como el genotipo del espacio Φ_g y se realiza sobre el fenotipo del problema Φ_p . La función de mapeo de $\Phi_f \rightarrow \Phi_g$ es llamada f_g y representa el tipo de representación implementada.

Así, el Algoritmo Genético pretende hallar una solución a un problema a partir de un subconjunto de Φ_p que es mapeado a Φ_g donde el problema puede ser tratado descomponiéndolo en pequeños sub problemas o bloques que se recombinan, conservando las mejores características. Para lograr la correcta selección de los elementos a ser tratados mediante los operadores genéticos es necesario definir una función a través de la cual se pueda establecer una relación de orden de cada una de las posibles soluciones del espacio Φ_g ; esta función es llamada función de aptitud $f(x)$:

$$f(x) = \Phi_g \rightarrow \mathbb{R} \tag{2.12}$$

De esta forma, en un problema de optimización, el valor óptimo \hat{x} queda definido como:

$$\hat{x} = \max_{x \in \Phi_g} f(x) \tag{2.13}$$

Donde x representa el vector de variables de decisión o alelos.

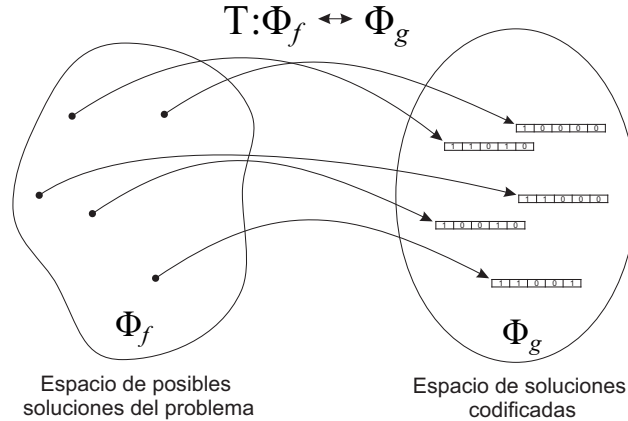


Figura 2.13: Transformación del espacio de búsqueda

Se han implementado diferentes tipos de representaciones en los Algoritmos Genéticos, siendo las más comunes la representación binaria y la representación real. Otras más, incluyen a la representación mediante códigos de gray, representaciones matriciales y de árbol. El uso de una representación específica puede ser útil si hay limitaciones o restricciones en el espacio de búsqueda que pueden ser ventajosamente modeladas por una codificación en especial.

1. Representación binaria:

Es el tipo de representación más usada en los Algoritmos Genéticos. El espacio de búsqueda está representado por una cadena de caracteres $\Phi = \{0, 1\}^l$ donde la cadena formada por la concatenación de los parámetros del problema es de longitud l y se encuentran codificados en un sistema binario $x^g = (x_1^g, \dots, x_l^g) \in \{0, 1\}^l$. Cuando se codifica una variable fenotípica continua usando un vector binario de longitud l , la precisión máxima es $\frac{1}{2^{l+1}} + 1$

2. Representaciones enteras:

En este tipo de representaciones se emplean alfabetos con una cardinalidad de tamaño X mayor a dos. El tamaño del espacio de búsqueda en este caso es de $|\Phi_g = X^l|$.

3. Representaciones con valores reales:

En las representaciones de este tipo se emplean valores reales en la cadena o cromosoma. El espacio de búsqueda Φ_g se define como $\Phi_g = \mathbb{R}^l$ donde l es el tamaño del cromosoma.

Cuando se emplean representaciones con valores reales, los investigadores regularmente favorecen Algoritmos Genéticos basados en la mutación como principal estrategia de evolución [44].

requieran más bits para representar la información pero no incrementan la cantidad de información representada.

Las representaciones son uniformemente redundantes si cada fenotipo es, en promedio, representado por el mismo número de genotipos. A su vez, el tipo de redundancia se puede considerar sinónima y no sinónima. Una representación es redundante sinónima si los genotipos que se asignan a el mismo fenotipo son similares entre sí. Por el contrario, una representación es redundante no-sinónima si los genotipos que se asignan al mismo fenotipo no son similares entre sí.

En una representación no-sinónima, pequeños cambios realizados con el operador de mutación pueden originar grandes cambios en el fenotipo.

2. Escalabilidad:

La escalabilidad se refiere al grado de relevancia de los bits en una cadena o cromosoma. Al realizar el mapeo de los fenotipos a genotipos, puede variar la importancia de los alelos.

Usar representaciones en las que todos los alelos son igualmente relevantes es equivalente a la situación en la que los bloques constructores son uniformemente escalados. Un escalamiento uniforme favorecerá la solución de bloques constructores en paralelo mientras que en representaciones escaladas no uniformes, los bloques constructores no son resueltos a la misma velocidad sino secuencialmente y ocurre una convergencia dominó.

Una codificación binaria muestra un tipo de escalamiento no uniforme en el que los alelos del genotipo tienen una contribución exponencial en relación a los del fenotipo. Este tipo de representación es llamado representación exponencialmente escalada.

3. Localidad:

La localidad de una representación hace referencia a la correspondencia de los vecinos de un genotipo con los vecinos de un fenotipo. Se asume que soluciones con características similares se encontrarán cercanas. Es decir, buenas soluciones se hallarán próximas a otras buenas soluciones, favoreciendo una búsqueda guiada. En caso contrario, la búsqueda se torna aleatoria. La similitud de los individuos está determinada por la métrica definida en el espacio de búsqueda y determina la dificultad de un problema.

Otro factor en la determinación de dificultad de un problema es el grado de correlación entre la métrica de la función de adaptación y la métrica del fenotipo. Los problemas se volverán más difíciles de resolver si los valores de la función de adaptación no están correlacionados con las distancias entre los valores óptimos. Una alta localidad favorecerá el desempeño de los operadores genéticos.

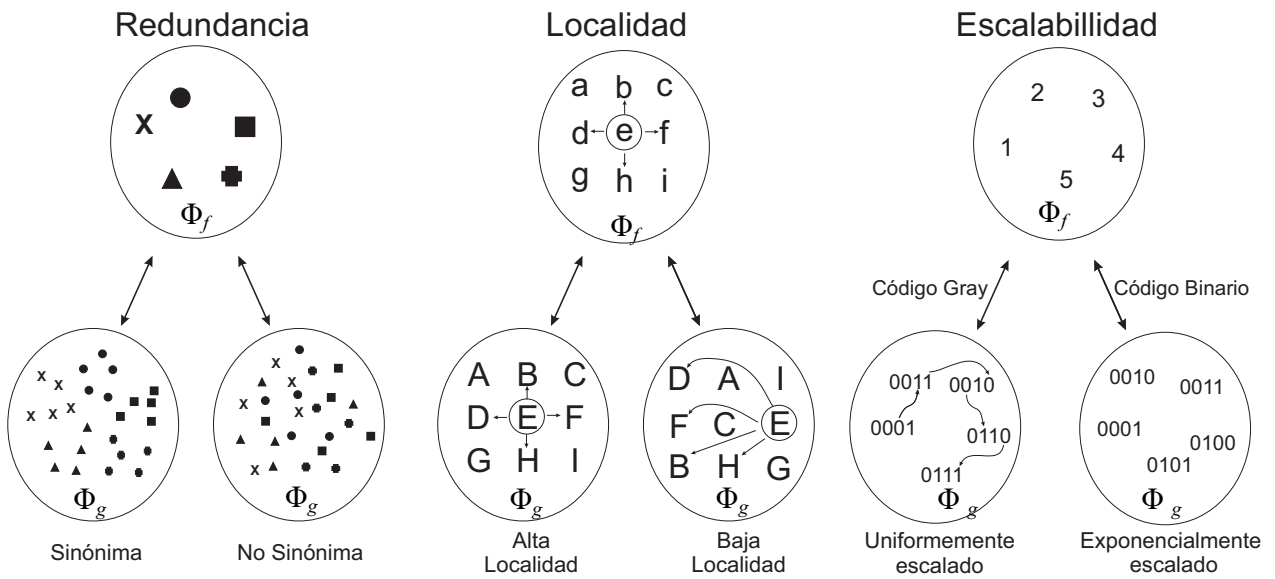


Figura 2.15: Características de la representación

2.7.2 Operadores genéticos

Un Algoritmo Genético parte de una población aleatoria inicial de la cual se espera evolucione a un estado en el cual pueda hallarse una solución cercana a la óptima. Para realizar esta búsqueda es necesaria la generación de nuevas soluciones posibles (Descendientes) a partir de las características de los individuos hallados (Padres). Para crear los descendientes, se usan operadores genéticos como la mutación y recombinación. Los operadores de mutación cambian el genotipo de un individuo ligeramente, mientras que los operadores de recombinación combinan la información genética de los padres para crear nuevos descendientes.

Los operadores genéticos tienen la función de realizar la exploración y explotación del espacio de soluciones en forma conjunta. La implementación de estos debe ser de tal manera que pueda hallarse un balance entre el grado de exploración y explotación requerida. Una implementación incorrecta de los operadores puede generar búsquedas aleatorias al eliminar soluciones halladas, no seleccionar en forma correcta los mejores individuos, o no permitir la combinación adecuada de las características de los padres.

Los operadores genéticos comúnmente empleados en los Algoritmos Genéticos son:

1. Selección
2. Cruce
3. Mutación

2.7.3 Selección

Mediante este operador se eligen los individuos candidatos a reproducirse, haciendo uso para ello de la función de aptitud que define el grado de adaptación de cada individuo, favoreciendo en forma probabilista las mejores soluciones.

Las técnicas de selección comúnmente usadas son:

1. Selección proporcional:

Los individuos son seleccionados de acuerdo a su contribución a la función de aptitud de la población. Dentro de estas técnicas se incluyen el Sobrante Estocástico, Universal Estocástico, Sobrante Determinístico, selección de Boltzmann, Escalamiento Sigma y selección por Ruleta, gozando esta última técnica de gran popularidad en los Algoritmos Genéticos.

2. Selección por torneo:

Se realiza una comparación directa entre un subconjunto de individuos (generalmente de tamaño 2, pudiendo ser mayor) tomados de forma aleatoria. La forma de seleccionar el ganador puede ser de forma determinista (el mejor individuo es seleccionado) o probabilista (se asigna un valor de probabilidad de seleccionar al mejor individuo; en caso contrario, el peor individuo del subconjunto es seleccionado).

Algunas otras técnicas de selección son la selección de Estado Uniforme, Disruptiva, por Jerarquías lineales y Competitiva.

2.7.4 Cruce

El operador de cruce en los Algoritmos Genéticos pretende generar nuevos individuos a partir de la combinación de los elementos y características de 2 individuos llamados padres. Esta combinación puede realizarse en diferentes formas, en función de la representación empleada. Dentro de la representación binaria se tienen los tipos de cruce:

1. Cruce en un punto
2. Cruce en 2 puntos
3. Cruce Uniforme

En la figura 2.16 se ejemplifica cada uno de estos.

En la representación con valores reales, el operador de cruce puede aplicarse de forma análoga a los tipos de cruce definidos en las representaciones binarias. Algunos otros modelos se han definido buscando imitar el rompimiento de los cromosomas como en las representaciones binarias, siendo los principales :

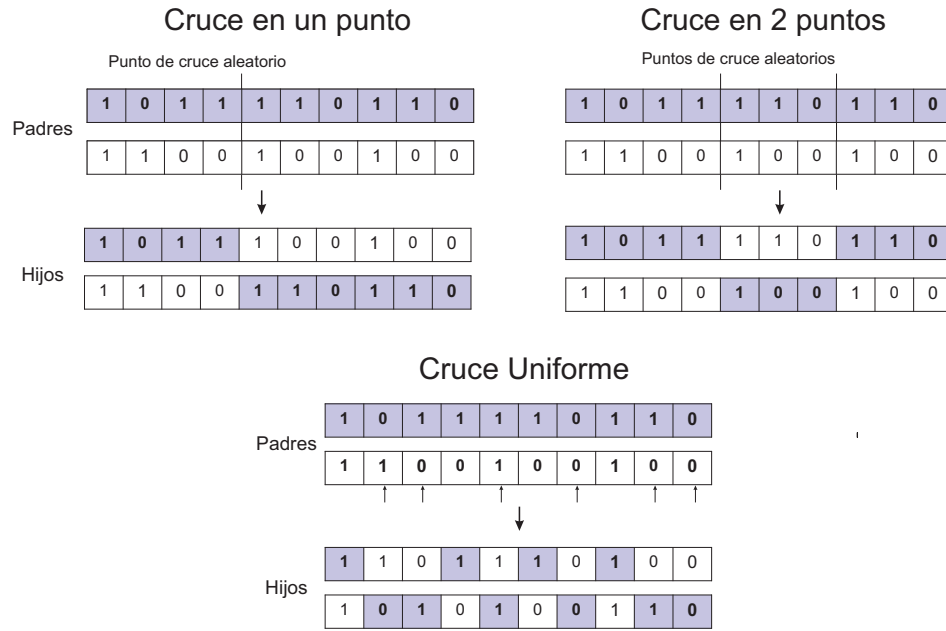


Figura 2.16: Operador de cruce en representaciones binarias

1. Cruza intermedia

Sean los padres:

$$P_1 = \langle v_1, \dots, v_k, \dots, v_m \rangle \quad (2.14)$$

$$P_2 = \langle w_1, \dots, w_k, \dots, w_m \rangle \quad (2.15)$$

La cruza en la posición k queda definida como:

$$O_1 = \langle v_1, \dots, v_k, a \cdot w_{k+1} + (1-a)w_{k+1}, \dots, a \cdot v_m + (1-a)w_m \rangle \quad (2.16)$$

$$O_2 = \langle w_1, \dots, w_k, a \cdot w_{k+1} + (1-a)v_{k+1}, \dots, a \cdot w_m + (1-a)v_m \rangle \quad (2.17)$$

con $a \in [0, 1]$

2. Cruza aritmética total

Los descendientes son generados mediante:

$$H_1 = \langle av_1 + (1-a)w_1, \dots, a \cdot w_k + (1-a)w_k, \dots, a \cdot v_m + (1-a)w_m \rangle \quad (2.18)$$

$$H_2 = \langle aw_1 + (1-a)v_1, \dots, a \cdot w_k + (1-a)v_k, \dots, a \cdot w_m + (1-a)v_m \rangle \quad (2.19)$$

3. Cruce binario simulado (Simulated Binary Crossover)

El algoritmo es:

- (a) Generar número aleatorio $u \in [0, 1]$

(b) Calcular $\bar{\beta}$:

$$\bar{\beta} = \begin{cases} (2u)^{\frac{1}{n_c+1}} & \text{si } u \leq 0.5 \\ \left(\frac{1}{2(1-u)}\right)^{\frac{1}{n_c+1}} & \text{de lo contrario.} \end{cases} \quad (2.20)$$

(c) Crear los descendientes:

$$H_1 = 0.5 [(P_2 + P_1) - \bar{\beta} | P_2 - P_1 |] \quad (2.21)$$

$$H_2 = 0.5 [(P_2 + P_1) + \bar{\beta} | P_2 - P_1 |] \quad (2.22)$$

2.7.5 Mutación

El operador de mutación, a diferencia de la cruce, pretende generar nuevos individuos a través de la modificación aleatoria de las características de la descendencia generada por los padres. Estas modificaciones permiten explorar el espacio buscando nuevas soluciones en regiones que pudieran encontrarse fuera de las posibles generadas por el operador de cruce.

El modelo clásico de mutación en cadenas binaria es presentado en la figura 2.17 en el que se elige un individuo con una probabilidad P_m a ser mutado y el valor del bit es intercambiado.




Figura 2.17: Mutación binaria

Para el caso de la representación con valores reales, la cardinalidad del alfabeto es mayor, por lo que es necesaria la implementación de operadores que puedan explorar todo el espacio. Algunos de los operadores que se han implementado son la mutación uniforme, la mutación de límite, la mutación no uniforme y la mutación basada en parámetros (Parameter-Based Mutation).

Dado:

$$I = \langle V_1, \dots, V_k, \dots, V_m \rangle \quad (2.23)$$

El individuo mutado será:

$$I' = \langle V'_1, \dots, V'_k, \dots, V_m \rangle \quad (2.24)$$

Donde V'_k se define en la tabla 2.2:

Tabla 2.2: Mutación para representación con valores reales

Tipo de mutación	Valor del Elemento Mutado
No Uniforme	$V'_k = \begin{cases} LI & \text{si flip}(0.5) = \text{Cierto} \\ LS & \text{de lo contrario} \end{cases}$
De Límite	$V'_k = \begin{cases} V_k + \Delta(t, LS - V_k) & \text{si flip}(0.5) = \text{Cierto} \\ V_k + \Delta(t, LI - V_k) & \text{de lo contrario} \end{cases}$
Uniforme	$V'_k = rnd(LB, UB)$

Con: $\Delta(t, y) = y \cdot (1 - r^{1 - \frac{t}{T}})$

Donde LS es el límite superior, LI es el inferior, T es el número máximo de generaciones y b es el grado de uniformidad.

2.7.6 Teorema de los esquemas

Un esquema $h = (h_1, h_2, \dots, h_n)$ es definido como una cadena ternaria de longitud l , donde $h_i = \{1, 0, *\}$ y $*$ representa un valor no fijo. En la figura 2.18 se presenta esquemáticamente la definición. El número de posiciones con valor explícito de un esquema se denomina orden del esquema y se denota como $o(H)$. La distancia entre la primera y la última posición explícita se denomina longitud de definición $\delta(H)$.




Figura 2.18: Definición de Esquema.

El teorema de los esquemas es el modelo matemático más usual en la descripción del funcionamiento de los Algoritmos Genéticos. Propuesto por Holland [24], el teorema describe cómo el número de instancias o copias de un esquema h cambia a través del paso de las generaciones dependiendo de la selección, cruce y mutación cuando se emplea un Algoritmo Genético con selección proporcional, cruza de un punto y mutación mediante intercambio de bits:

$$m(h, t + 1) \geq \frac{f(h, t)}{\bar{f}(t)} \left(1 - p_c \frac{\delta(h)}{l - 1} - p_m o(h)\right) \quad (2.25)$$

donde:

$m(h, t)$ es el número de instancias del esquema h en la generación t

$f(h, t)$ es la función de aptitud del esquema h en la generación t .

$\bar{f}(t)$ es el promedio de la función de aptitud de la población en la generación t

P_m es la probabilidad de mutación

P_c es la probabilidad de cruza

2.7.7 Hipótesis de los Bloques Constructores

Goldberg [18] define a los bloques constructores (**BBs**) como esquemas de bajo orden (longitud de definición pequeña) y responsables de una aptitud elevada, que al ser muestreados, recombinados y re-muestreados a través de las generaciones forman cadenas con un grado de adaptación potencialmente alto, incrementando exponencialmente las muestras de los mejores individuos observados.

La hipótesis de los bloques constructores básicamente establece que los Algoritmos Genéticos operan funcionalmente principalmente debido a la habilidad de propagar bloques constructores, generando buenas soluciones globales a través de la combinación de esquemas de bajo orden con alta capacidad para producir una aptitud elevada.

A su vez, un bloque constructor puede ser descrito como una solución con un alto ajuste a un sub-problema que puede ser expresado como un esquema [44]. Si las sub-soluciones a un problema (los BBS) son cortas y de orden bajo entonces el número de sub-soluciones correctas incrementa a través de las generaciones y el problema puede ser resuelto fácilmente por los Algoritmos Genéticos. Es decir, el procesamiento de los bloques constructores está basado en la cuasidescomposición de un problema [18]. Resolviendo estos sub-problemas de forma separada y combinando las buenas soluciones, un AG puede encontrar buenas soluciones a problemas de optimización global [19].

Un problema puede ser descompuesto apropiadamente identificando las interdependencias entre los diferentes alelos. El propósito de los operadores genéticos es descomponer el problema detectando los alelos responsables de elevar la aptitud.

Goldberg [20] resume en seis puntos las condiciones para una exitosa aplicación de los Algoritmos Genéticos en función de los bloques constructores:

1. Saber qué está procesando el Algoritmo Genético: Bloques constructores
2. Asegurar un suministro adecuado de bloques constructores, ya sea inicialmente o temporalmente
3. Asegurar el crecimiento de bloques constructores necesarios
4. Asegurar la mezcla de los bloques constructores necesarios

5. Resolver problemas que son tratables mediante bloques constructores o re-codificarlos para que lo sean
6. Decidir correctamente entre los bloques constructores competidores

El primer punto hace referencia a la descomposición del problema en sub problemas (bloques constructores). En el segundo punto se hace referencia al muestreo de la población inicial y el muestreo durante la búsqueda. El tercer y cuarto punto se refieren a la aplicación correcta de los operadores que permitan combinar y conservar las mejores características de una solución y por su parte el quinto punto está relacionado con el tipo de representación del problema, mientras que el último se relaciona con la función de aptitud y el método de selección implementados.

2.8 Aplicación de los Algoritmos Genéticos a las Redes Neuronales Artificiales

Las características propias de los Algoritmos Genéticos han resultado particularmente útiles en problemas de optimización en los que se tienen espacios muy grandes y complejos y con funciones multimodales, no diferenciables y propensas a producir errores [56]. Un ejemplo de esto es la generación automática de Redes Neuronales y la modificación de sus parámetros.

Una característica destacada de los sistemas evolutivos en Redes Neuronales es que pueden evolucionar hacia la más apta en un entorno de trabajo sin interferencias externas. Por lo tanto, se elimina el tedioso trabajo de ensayo y error normalmente requerido para encontrar una Red Neuronal óptima para una tarea sobre la cual el conocimiento previo puede ser escaso.

Según Yao [56], las características que hacen a la búsqueda de la arquitectura de una RNA propia para su uso mediante Algoritmos Genéticos es:

1. Se trata de un superficie de búsqueda amplia. No esta limitado el número posible de nodos y conexiones en una Red.
2. la Superficie es no diferenciables, pueden haber discontinuidades debido a que el número de nodos o conexiones es discreto.
3. La superficie depende de las condiciones iniciales. la superficie es compleja y ruidosa.
4. Se trata de una superficie deceptiva. Arquitecturas muy similares pueden tener desempeños muy diferentes.
5. La superficie es multimodal. Diferentes arquitecturas pueden presentar desempeños similares.

Los algoritmos evolutivos han sido introducidos dentro de las RNA principalmente en tres campos [57]:

1. Evolución de Conexiones

2. Evolución de Arquitecturas
3. Evolución de Reglas de Aprendizaje

La evolución de las conexiones de los pesos tiene un enfoque adaptativo y global de entrenamiento y es especialmente útil cuando el gradiente de información no está disponible o es computacionalmente muy costoso de obtener para trabajar con algoritmos de entrenamientos basados en el gradiente del error. La evolución de las arquitecturas permite a las RNA adaptar sus topologías a diferentes tareas sin la intervención humana. La evolución de las reglas de aprendizaje puede ser considerada como un proceso de aprender a aprender en las RNA donde la adaptación de las reglas se logra a través de la evolución.

2.8.1 Evolución de los pesos

La evolución de los pesos de una Red Neuronal Artificial mediante Algoritmos Genéticos se refiere a la optimización de los pesos de las conexiones en una red, intentando minimizar el error. Este enfoque se realiza principalmente con una estructura de la red fija definida. Para esto se codifica cada peso de la RNA como una cadena de caracteres, pudiendo ser ésta en forma binaria o real.

Varios trabajos desarrollados realizan la evolución de los pesos en forma conjunta del Algoritmo Genético y métodos clásicos como retropropagación. Este último enfoque consiste en aplicar el Algoritmo Genético a la selección del mejor entrenamiento con retropropagación en función de diferentes parámetros.

2.8.2 Evolución de la arquitectura.

La capacidad de procesamiento y habilidad de generalización de la información de las RNA está fuertemente determinada por su arquitectura [25], por lo que una aplicación exitosa de una RNA es dependiente del diseño y selección apropiado de la arquitectura de ésta. Una arquitectura muy grande puede sobreentrenar los datos debido a su exceso de capacidad de procesamiento de la información. Por otra parte, una arquitectura muy pequeña puede no ajustar bien los datos debido a su limitada capacidad de procesamiento de la información.

Algunos modelos para diseñar Redes Neuronales en forma automática hacen uso de técnicas como algoritmos constructivos, algoritmos destructivos y combinación de ambos. Un algoritmo constructivo agrega capas, neuronas y conexiones a una RNA mínima. Un algoritmo destructivo actúa en forma opuesta, eliminando capas ocultas, neuronas o conexiones innecesarias de una RNA de gran tamaño. Un algoritmo combinado (constructivo y destructivo) se ejecuta primero como algoritmo constructivo y posteriormente funciona como algoritmo destructivo.

El enfoque central en el uso de RNAs es elegir y generar la estructura topológica adaptándola a la dinámica del problema sin necesidad de intervención humana.

Otros modelos desarrollados buscan la evolución simultánea de arquitecturas y pesos de las conexiones. La principal ventaja de este enfoque es que esto puede evitar el problema de arquitecturas óptimas locales.

2.8.3 Evolución de reglas de aprendizaje

Un enfoque menos estudiado es la evolución de las reglas de aprendizaje. En este enfoque se adaptan las reglas de aprendizaje a través de la evolución. Esto puede ser visto como el enseñar a la red neuronal a aprender.

La relación entre el aprendizaje y la evolución es muy compleja. Una RNA debe poseer la capacidad de ajustar su regla de aprendizaje de forma adaptativa en función de su arquitectura y la tarea a realizar, es decir, debe aprender en forma dinámica de su regla de aprendizaje, en lugar de que sea diseñada y fijada manualmente.

Capítulo 3

Metodología

El proceso de monitoreo y seguimiento de la combustión permite conocer el estado del proceso, mediante el cual se puede hacer un control adecuado de éste, mejorando así la combustión y reduciendo costos de operación a la vez que el proceso se hace más fiable y limpio. La comprensión de los parámetros involucrados en la combustión es de gran importancia en el control del proceso. Sin embargo, la dinámica de la combustión es compleja, lo cual dificulta su modelado mediante métodos deterministas clásicos.

Características de la flama tales como la frecuencia de parpadeo, radicales liberados, intensidad de la flama, entre otras propiedades pueden ser captadas a través del espectro electromagnético. El análisis correcto de esta señal permite encontrar correlaciones entre estos parámetros y patrones de flama definidos, que a su vez pueden estar asociados con parámetros propios del proceso de la combustión, como son la relación aire combustible, grado de exceso de combustible e incluso identificar posibles fallas en el equipo.

Este enfoque permite hacer uso de dispositivos usados como elementos de seguridad, convirtiéndolos en elementos que aportan información útil sobre el estado de la combustión, como es el caso de los detectores de flama.

La metodología desarrollada en este proyecto se presenta en la figura 3.1. En ésta se pueden observar dos etapas principales, La primera corresponde a la realización de las pruebas con señales de flama tomadas en un ambiente controlado, mientras que la segunda etapa hace referencia a pruebas con datos de un proceso de combustión real. En ambas etapas se incluye la adquisición de la señal, la identificación de los patrones de flama, así como el procesamiento y extracción de características de la señal.

El objetivo de la primera etapa comprende el análisis y procesamiento de la señal del espectro

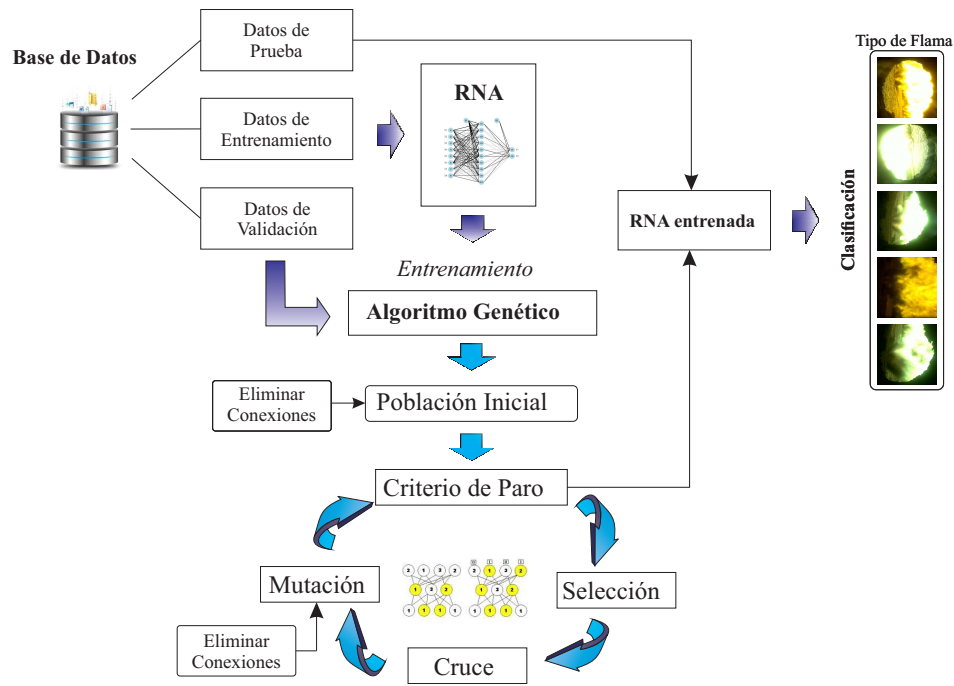


Figura 3.1: Metodología construida para la caracterización de los patrones de flama

electromagnético para la extracción de características y la validación del algoritmo de entrenamiento de una Red Neuronal basado en Algoritmos Genéticos. En esta etapa se identificaron 4 patrones de flama y se desarrolló el Algoritmo Genético que fue posteriormente implementado en el entrenamiento de la Red con datos del proceso real de combustión.

En la segunda etapa se realizó la caracterización de 5 patrones de flama de un sistema de combustión en quemadores. Para ello, se llevó a cabo el análisis de las señales de flama extrayéndose las mismas características que en la etapa de pruebas de laboratorio. Sin embargo, el proceso de la combustión bajo condiciones no controladas presenta mayor aleatoriedad, requiriendo un análisis más complejo, razón por la cual en esta etapa se incluyeron a su vez características extras como son: Características de señales oscilatorias, entropía, autocorrelación y algunos parámetros de la combustión.

A continuación se describen de forma detallada los apartados de la metodología implementada.

3.1 Adquisición de la señal

El espectro electromagnético del proceso de combustión fue captado usando un dispositivo de detección de flamas basado en un sensor óptico de estado sólido que opera en el rango ultravioleta (350 nm) al infrarrojo (700 nm). En la figura 3.2 se muestra un esquema de la comunicación y adquisición de datos mediante el detector de flama.

El detector de flama provee una salida hexadecimal de 450 datos, la cual contiene la configu-

ración del sensor y la señal de la flama en el dominio del tiempo y la frecuencia. La adquisición de los datos se realiza en un programa desarrollado en Visual Basic. El software inicializa enviando la configuración y solicitud al sensor a través del puerto serial, el cual comienza a adquirir la información, mientras el programa monitorea el puerto serial en espera de la respuesta y envío de la trama de datos (que incluyen la frecuencia, voltaje y configuración). Una vez recibida la información el programa procesa la trama convirtiéndola de hexadecimal a valores numéricos. Los valores obtenidos del detector son gestionados con Microsoft Access que crea una base de datos de cada prueba.

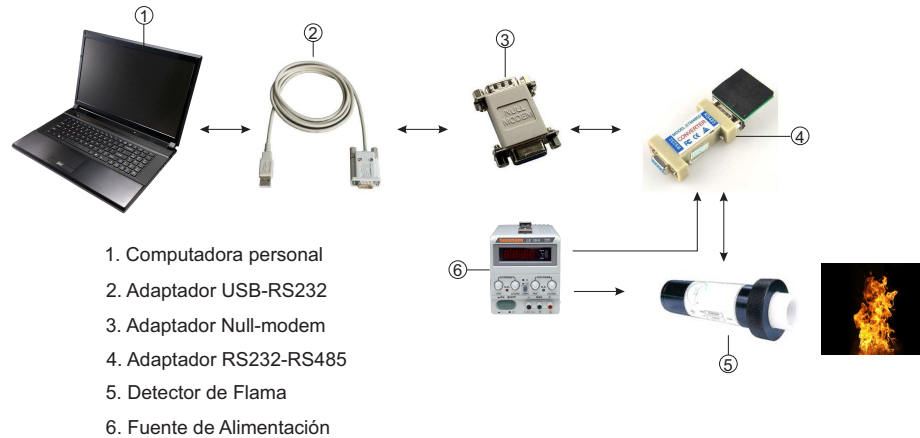


Figura 3.2: Diagrama de adquisición de datos con el detector de flama

3.1.1 Señales de laboratorio

Se generó una base de datos de señales del sensor correspondientes a cuatro tipos de flama. Estos estados fueron seleccionados basados en el porcentaje de aire combustible, siendo este un factor clave en el proceso de optimización de la combustión. Particularmente, se consideran tres condiciones en el balance de la relación: mezcla rica, mezcla pobre y una mezcla estequiométrica (balance aire-combustible). Por su parte, el estado de apagado en un sistema de combustión puede ser también de interés si existe riesgo de acumulación de combustible que puede originar explosiones. De este modo quedaron definidos los estados:

1. No flama: Radiación de fondo
2. Flama estable: Balance Aire-Combustible
3. Flama con exceso de aire: Mezcla pobre
4. Flama con exceso de combustible: Mezcla rica

Quedando conformada así la base de datos por 480 señales (120 de cada patrón de flama). Cada señal contiene 256 datos que corresponden al valor del voltaje equivalente a la intensidad de la flama en 500 ms. En la figura 3.3 se muestran las señales de datos correspondientes a los cuatro estados.




Figura 3.3: Señales de los patrones de laboratorio

3.1.2 Señales del proceso real de combustión en la unidad de quemadores

El sistema de quemadores está conformado por 12 celdas de aceite combustible. Los quemadores están ubicados en las paredes frontal y posterior, y distribuidos en dos niveles (A inferior y B superior) y cuentan con diferentes puertos (mirillas) en las esquinas superiores del hogar desde donde se pueden observar de manera lateral y hacia abajo las flamas. En la figura 3.4 se muestra la disposición de éstas. Cada una de las celdas está compuesta por 2 quemadores (uno superior y otro inferior), cada uno con su correspondiente piloto. Cada par de quemadores cuenta con un registro de aire secundario. El aire secundario se introduce en el lado adyacente de las paredes de combustión. Sin embargo, la caja de aire tiene un diseño de aislamiento exterior para reducir al mínimo la estratificación del aire de la caja de aire. Además cuenta con un horno balanceado, una unidad de recalentamiento y está equipada con la recirculación de gases (EGR) para el control de la temperatura del vapor, así como atemperadores de spray y sopladores.

La flama en cada quemador y piloto es monitoreada mediante un Detector de Flama que mide el espectro electromagnético. Estas señales (del quemador y piloto) son usadas en el sistema de combustión como doble medida de seguridad para prevenir el apagado de quemadores en etapa de funcionamiento y para detectar quemadores que se encuentren tapados.

La unidad cuenta con flujómetros instalados en cada uno de los quemadores y con un sistema de adquisición de datos de los parámetros de la combustión HMIs (Human Machine Interface), que recolectan la información de los principales parámetros que incluyen el flujo, densidad y temperatura del combustible, exceso de oxígeno y presión de atomización. Esta información es administrada a su vez en las bases de datos con Microsoft Access.

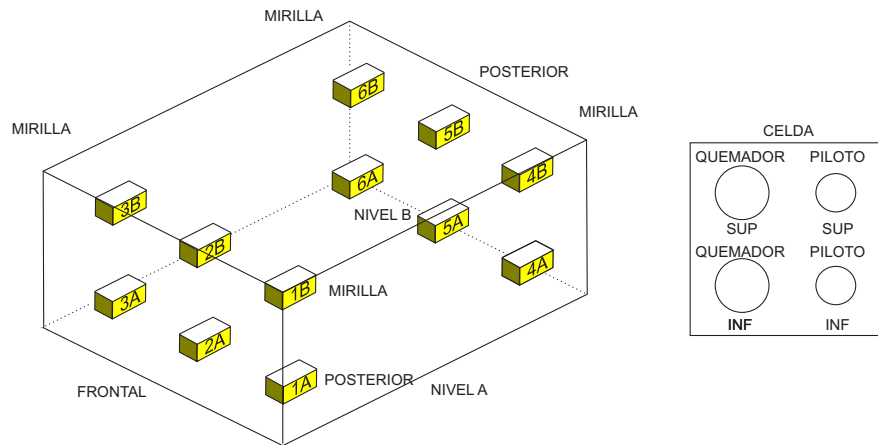


Figura 3.4: Disposición de los quemadores del sistema de combustión

A través de la realización de diversas pruebas en la variación de los parámetros de operación en el proceso de combustión, específicamente, en los porcentajes de oxígeno, presión de atomización y temperatura del combustible, se obtuvo la base de datos de las señales del sistema de quemadores. En la tabla 3.1 se presentan los parámetros con los cuales realizaron las observaciones y mediante los cuales se generó dicha base de datos.

Tabla 3.1: Parámetros del sistema de quemadores

Parámetro	Valores	Unidades
Exceso de oxígeno	3.0, 3.5, 4.0, 4.5	%
Presión de Atomización	11, 15, 18	bar
Flujo de combustible	Valores medidos mediante flujometros	T/Hr

A través de estas pruebas, se identificaron 5 patrones diferentes de flama presentes en las condiciones de operación, los cuales son:

1. Estado 1: La flama tiene una intensidad baja, longitud pulsante, errática y está separada.
2. Estado 2: La flama es corta, separada, abierta y poco intensa.
3. Estado 3: La flama es óptima, intensa y brillante.
4. Estado 4: La flama es alargada, sesgada, débil y opaca.
5. Estado 5: La flama es rica en trazas de inquemados, separada, errática y opaca.

El estado 1 está caracterizado por un porcentaje de exceso de oxígeno y presión de combustible bajos. El estado 2 tiene ocurrencia en condiciones de presión de atomización baja y alto porcentaje de exceso de oxígeno. El estado 3 se presenta bajo condiciones estables de operación. Mientras que el estado 4 es característico de una elevada presión de atomización en combinación de un bajo porcentaje de exceso de oxígeno. Mientras que el estado 5 ocurre en presencia de un alto flujo de

combustible y un bajo porcentaje de exceso de oxígeno.

Las señales analizadas en esta pruebas corresponden a los datos de 3 de los 24 quemadores: los Quemadores Superior e Inferior de la celda 5A y el Quemador Superior de la celda 6B. Las señales de estos 3 quemadores abarcan en la totalidad los 5 estados de la flama identificados. Cada señal de los quemadores se encuentra además conformada por 4 tramas de datos con 256 valores cada una, correspondientes a 500 ms de muestreo, y que fueron tomadas cada minuto. De tal forma una serie corresponde a 1024 datos. En la figura 3.5 se muestran a manera de ejemplo señales de los tres quemadores empleados en el análisis.

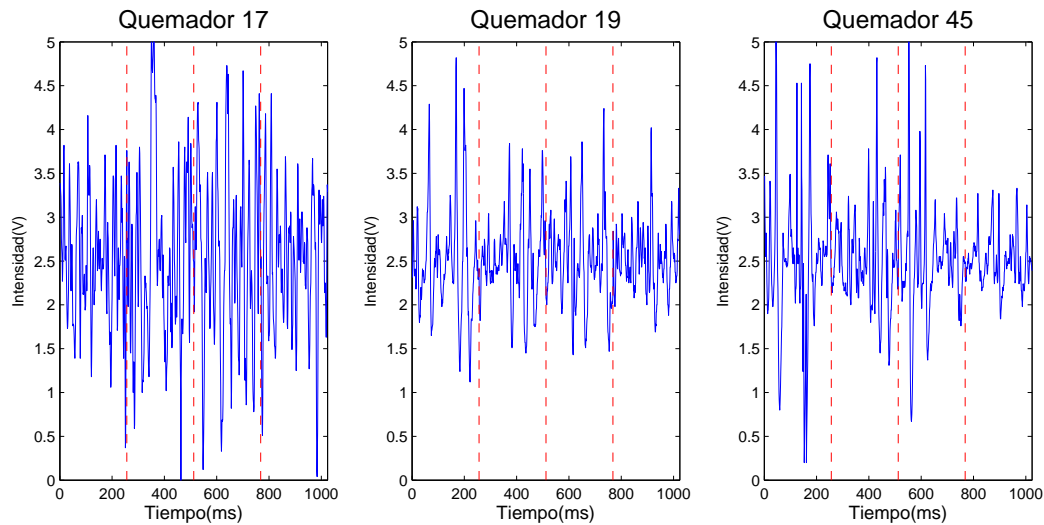


Figura 3.5: Señales de los quemadores

3.2 Pre-procesamiento de la señal

El pre-procesamiento de los datos es una etapa que permite el uso de menos variables de entrada en una Red Neuronal; este pre-procesamiento es llamado extracción de características. La extracción de las características adecuadas que representen en mejor medida la dinámica del problema a resolver es un factor clave en el resultado final. Otra razón que justifica la extracción de características es la reducción de dimensión, que permite descartar información redundante o de poca relevancia.

Se realizó la extracción de diversas características asociadas a las señales con el objetivo de suministrar a la Red Neuronal entradas a través de las cuales fuera posible la clasificación de los patrones de flama. Cada una de las características fue normalizada dentro del rango de $[-1, 1]$, siendo las características extraídas:

3.2.1 Características estadísticas

3.2.1.1 Momentos estadísticos

El valor esperado de una variable aleatoria y su varianza son dos características importantes de las variables aleatorias pues proveen información sobre el valor central de la variable y su dispersión alrededor del valor central. De esta forma, hay otros índices de las variables aleatorias que son usados para indicar algunas otras características de su distribución; uno de éstos, son los llamados momentos.

El análisis de momentos estadísticos es una técnica que puede ser usada en la caracterización de series de datos, ya que provee un conjunto de parámetros que describen y proveen información de la función de distribución de probabilidad.

Los momentos centrales de orden k son definidos como:

$$M_k = E[x - E(x)]^k \quad (3.1)$$

Donde:

M_k = Momento estadístico de orden k

$E[\]$ = Valor esperado

x = Señal o serie de tiempo

El segundo momento corresponde con la desviación estándar, que define la variabilidad de los datos. El tercer momento está relacionado con la simetría de la distribución de los datos, calculándose ésta como:

$$\gamma_1 = \frac{\mu_3}{\mu_2^{\frac{3}{2}}} \quad (3.2)$$

El cuarto momento está relacionado con la forma de la distribución, también llamada curtosis, que se define como:

$$\gamma_2 = \frac{\mu_4}{\mu_2^2} \quad (3.3)$$

En este análisis se calcularon el segundo, tercero y cuarto momento centralizado de la distribución de la señal de la intensidad de la flama.

3.2.1.2 Autocorrelación

La autocorrelación mide la correlación lineal en una serie de tiempo y es útil en la determinación de la aleatoriedad, tendencias y patrones en las series de datos al contrastar sus propios valores pasados y futuros con un tiempo de retraso τ . De este modo, la determinación de tendencias en la señal puede ser de especial utilidad en la clasificación de patrones.

La suma de los cuadrados de las autocorrelaciones Q_m también llamada estadística Box-Pierce,

permite verificar si una serie de tiempo es un proceso aleatorio (ruido blanco). En ese caso todos los coeficientes de autocorrelación serán cero y Q_m tiene una distribución ji-cuadrada con m grados de libertad.

La suma de la autocorrelación con un retraso τ_{max} se calcula mediante:

$$Q(\tau_{max}) = n \sum_{\tau=1}^{\tau_{max}} r(\tau)^2 \quad (3.4)$$

Donde:

$$r(\tau) = \frac{\sum_{t=\tau+1}^n (x_t x_{t-\tau} - \bar{x}^2)}{\sum_{t=\tau+1}^n x_t^2 - \bar{x}^2} \quad (3.5)$$

3.2.2 Análisis de Componentes Principales (PCA)

El Análisis de Componentes Principales es una técnica de transformación que puede ser útil para revelar estructuras simples, patrones o tendencias subyacentes en conjuntos de datos complejos usando soluciones analíticas. Esta técnica provee una medida a través de la cual es posible cuantificar la importancia relativa de cada dimensión, permitiendo la caracterización de conjuntos grandes mediante un número reducido de componentes, que puede ser visto como una reducción de dimensión.

Geoméricamente, el primer componente principal es la línea más cercana que ajusta a las n observaciones en el espacio de variables p dimensional. Éste minimiza la suma del cuadrado de las distancias de las n observaciones de la línea en el espacio de variables representando los primeros Componentes Principales [11].

Algebraicamente, los Componentes Principales Y_i son la combinación lineal de las p variables $X = x_1, x_2, \dots, x_p$ tomadas de n observaciones:

$$Y_i = a_{i1}x_1 + a_{i2}x_2 + \dots + a_{ip}x_p = \sum_{j=1}^p a_{ij}x_j \quad (3.6)$$

Tal que la varianza de Y_i es maximizada con la restricción que la suma del cuadrado de los pesos sea igual a uno:

$$\sum_{j=1}^p a_{ij}^2 = 1 \quad (3.7)$$

o bien :

$$Y_i = X \cdot a_i^t \quad (3.8)$$

A través de la descomposición de valores y partiendo de la matriz X de $(n \times p)$, donde $X^t X$ es

una matriz cuadrada de rango p , X se puede expresar como:

$$X = U\Sigma V^t \quad (3.9)$$

Donde U y V son matrices de orden n que contienen los eigenvectores de X^tX , y Σ es una matriz diagonal que contiene la raíz cuadrada de los eigenvalores de X^tX : $(\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_p)$, con $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq \dots, \lambda_p > 0$.

Siguiendo esta metodología, se realizó el Análisis de Componentes Principales aplicado a las señales electromagnéticas. Para ello se partió de la construcción de la matriz de distancias de los datos de cada señal, que fue descompuesta en sus valores singulares, obteniéndose así una matriz Σ para cada señal que contiene los eigenvalores asociados a sus componentes principales. Los eigenvalores de esta matriz caracterizan el comportamiento de cada señal. Bajo este modelo señales, con estructuras semejantes, tendrán Componentes Principales similares.

El procedimiento aplicado con PCA es mostrado en la figura. 3.6




Figura 3.6: Aplicación de PCA en las señales del detector

La obtención de los Componentes Principales permite, mediante un número reducido de parámetros, caracterizar un conjunto de datos. De este modo, la selección del número de componentes permite emplear k componentes que retengan la mayor cantidad de información. Los criterios de selección se basan en porcentajes de variabilidad y retención de información; algunos de éstos son:

1. **Criterio Kaiser:** Se retienen todos los componentes que tienen asociado un eigenvalor mayor que uno. Este criterio se basa en que la cantidad de varianza explicada mediante el número de componentes extraídos. Dicha varianza está directamente relacionada con los eigenvalores asociados a los componentes. Los Componentes se extraen de forma consecutiva. La extracción finaliza cuando el eigenvalor asociado al último componente extraído es inferior a 1.
2. **Medias Aritméticas:** Se seleccionan los componentes cuyo eigenvalor asociado λ_j excede la media de eigenvalores. Los componentes retenidos serán aquellos que cumplan:

$$\lambda_k > \bar{\lambda} = \frac{\sum_{j=1}^p \lambda_k}{p} \quad (3.10)$$

3. **Gráfico de sedimentación:** Se realiza la representación de los componentes mediante un gráfico formado por el número de componentes (eje de las abscisas) y su correspondiente eigenvalor característico (eje de las ordenadas) ordenados en forma decreciente. El número de componentes a retener se determina identificando el punto en el que existe un cambio de una pendiente pronunciada a una pendiente mínima.
4. **Porcentaje de varianza acumulada:** Este criterio se basa en el porcentaje de variabilidad explicada por los componentes, definiéndose un porcentaje satisfactorio dentro del cual se retienen los primeros k componentes. El porcentaje de variabilidad hasta el componente k se calcula como:

$$CV_k = \sum_{i=1}^k \frac{100\lambda_i}{\sum_{j=1}^m \lambda_j} \quad (3.11)$$

Donde:

CV_k = Varianza acumulada del Componente k

m = Número total de componentes

Aplicando el criterio del porcentaje de varianza acumulada, en la figura 3.7 se muestran los primeros 20 componentes principales de la señal de flama de la base de datos de laboratorio. Se puede observar que los primeros 5 componentes explican un 92.7 % de la variabilidad, mientras que el sexto componente incrementa la variabilidad en sólo un 1.28 %, por lo que el uso de los primeros 5 componentes es suficiente para explicar un alto porcentaje de la variabilidad de los datos.




Figura 3.7: Selección de los Componentes Principales

3.2.3 Características de señales oscilatorias

Las características relacionadas a señales oscilatorias fueron calculadas considerando comportamientos oscilatorios de las señales (aunque esto no siempre sea cierto). Para el cálculo de los picos, la

señal es recorrida con un ventana de longitud k , verificando si el centro es un mínimo o un máximo. El periodo de la oscilación se define como el tiempo entre dos picos sucesivos. Se calcularon de la señal, la media y desviación estándar del periodo y los picos, que están definidos como:

Media del Periodo:

$$\bar{T} = \frac{1}{n} \sum_{i=1}^n T_i \quad (3.12)$$

Donde:

T_i = Periodo de la i^{th} oscilación.

Media del Pico:

$$\bar{z} = \frac{1}{n} \sum_{i=1}^n z_i \quad (3.13)$$

Donde:

z_i = Pico de la i^{th} oscilación.

Desviación Estándar del Periodo

$$S_T = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (T_i^2 - \bar{T}^2)} \quad (3.14)$$

Desviación del Pico

$$S_z = \frac{1}{n-1} \sum_{i=1}^n (z_i - \bar{z}^2) \quad (3.15)$$

3.2.4 Entropía

La entropía de Shannon provee un criterio útil para el análisis y comparación de las distribuciones de probabilidad. Provee una medida de la información de cualquier distribución.

Para un sistema con cierta incertidumbre, si se usa una variable X con un número limitado de números y siendo la distribución de probabilidad:

$$\begin{bmatrix} X \\ P_j \end{bmatrix} = \begin{bmatrix} x_1, x_2, \dots, x_l \\ p(x_1), p(x_2), \dots, p(x_l) \end{bmatrix} \quad (3.16)$$

La Entropía es calculada como:

$$S = - \sum_{j=1}^l p_j \cdot \ln(p_j) \quad (3.17)$$

Donde $p_j = N_i/N$ cuando $N \rightarrow \infty$.

La entropía proporciona así una medida del número de diferentes micro estados que pueden tener lugar en un macro estado dado (medida del grado de desorden o incertidumbre).

El análisis mediante Wavelet, por su parte, es un método que utiliza una base de funciones ortogonales para proyectar una señal sobre el nuevo espacio que éstas representan. Además, una función arbitraria puede ser descompuesta de forma única y la descomposición se puede invertir. Una base Wavelet usa una serie de funciones con buena localización en tiempo y en frecuencia, creando una familia Wavelet. Ésta es el conjunto de funciones elementales formadas por dilataciones y traslaciones de la Wavelet madre $\psi_{a,b}$ [9].

$$\psi_{a,b} = |a|^{-\frac{1}{2}} \psi\left(\frac{t-b}{a}\right) \quad (3.18)$$

donde $a, b \in \mathbb{R}$, $a \neq 0$, son los parámetros de escala y traslación, y t el tiempo.

Se puede realizar una representación no redundante de la señal mediante la transformada Wavelet discreta, donde los valores son los coeficientes de la serie Wavelet. La información organizada en un esquema jerárquico es llamada análisis multirresolución.

La expansión Wavelet está dada por:

$$x(t) = \sum_{j=-N}^{-1} \sum_k C_j(k) \cdot \psi_{j,k}(t) = \sum_{j=-N}^{-1} r_j(t) \quad (3.19)$$

donde $\psi_{j,k}(t)$ es la función Wavelet madre con parámetros discretos $a_j = 2^{-j}$ y $b_{j,k} = 2^{-j}k$ con $j, k \in Z$. Los coeficientes $C_j(k)$ se interpretan como los errores locales entre las aproximaciones de las escalas j y $j + 1$, mientras que $r_j(t)$ es la señal de detalle en la escala j , siendo la potencia:

$$E_j = \sum_k |C_j(k)|^2 \quad (3.20)$$

Combinando la multirresolución Wavelet y la entropía, se puede definir la entropía Wavelet de una señal:

Si $E = E_1, E_2, \dots, E_m$ es igual al espectro de la entropía de la energía Wavelet de las m escalas de descomposiciones de la señal $x(t)$ y de la propiedad de las Wavelets ortogonales, se tiene que la energía total E es igual a la suma de la potencia E_j dentro de una ventana de tiempo w . Además, siendo $p_j = E_j/E$, entonces $\sum_j p_j = 1$; así, la entropía de la energía Wavelet está definida como:

$$W_{EE} = - \sum_j p_j \log(p_j) \quad (3.21)$$

W_{EE} mide el grado de desorden de la señal; en una señal aleatoria su descomposición tendría valores similares en todas las escalas, y las E_j normalizadas serían muy similares para todos los niveles de descomposición por lo que W_{EE} tomaría un valor cercano a uno.

3.3 Implementación del Algoritmo Genético y la Red Neuronal Artificial

Las características de los Algoritmos Genéticos los han hecho particularmente útiles en espacios grandes en los que no se tiene conocimiento sobre el gradiente de búsqueda. Por su parte, los métodos de entrenamiento usados en Redes Neuronales están basados en el gradiente del error cuadrático, pudiendo esta función caer en mínimos locales.

En esta sección se describe la metodología de la implementación del Algoritmo Genético usado para el entrenamiento de la Red Neuronal y que se encuentra esquematizado en la figura 3.8. Este diagrama parte de las bases de datos de las características extraídas de las señales del espectro electromagnético e incluye la implementación de la arquitectura de la Red Neuronal Artificial y de los operadores del Algoritmo Genético para su entrenamiento.

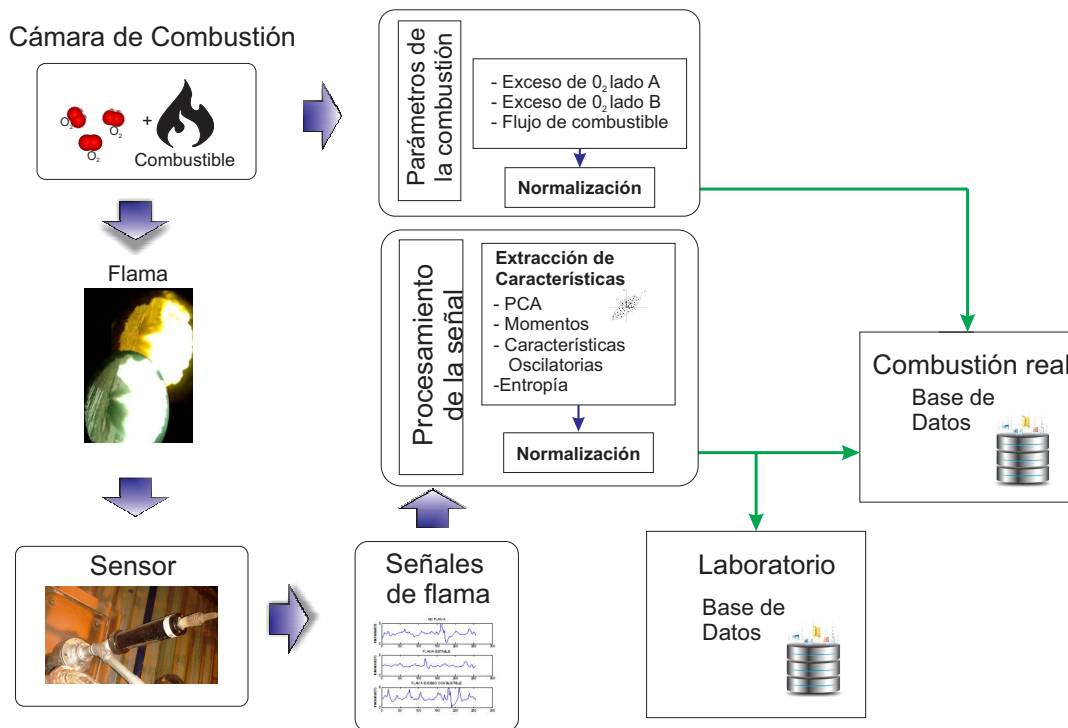


Figura 3.8: Entrenamiento de la Red Neuronal mediante un Algoritmo Genético

El entrenamiento de la Red Neuronal inicia tomando las señales de cada base de datos, las cuales son divididas de forma aleatoria en 3 subgrupos:

1. *Datos de Entrenamiento*: Datos usados para el entrenamiento de la Red Neuronal. Corresponde al 50% del total de la base de datos.
2. *Datos de Validación*: Datos usados para calcular el porcentaje de generalización. Una Red Neuronal entrenada correctamente tendrá un alto grado de generalización. El porcentaje del total de los datos usados para validación corresponden al 25%.

3. *Datos de Prueba:* Datos que son usados para prueba y verificación del entrenamiento de la Red. Corresponde al 25% del total de cada base de datos.

En la Tabla 3.2 se muestran resumidos los porcentajes y número de señales de cada base de datos usadas en la clasificación de los patrones de flama.

Tabla 3.2: Bases de datos de las señales

Base de datos		P_1	P_2	P_3	P_4	P_5	Señales totales
Laboratorio	Entrenamiento	60	60	60	60	-	240
	Validación	30	30	30	30	-	120
	Prueba	30	30	30	30	-	120
	Total	120	120	120	120	-	480
Unidad de Quemadores	Entrenamiento	8	17	23	16	15	79
	Validación	4	8	11	8	7	38
	Prueba	5	9	12	8	8	42
	Total	17	34	46	32	30	159

Una vez seleccionados los datos, se procede al entrenamiento de la red con el Algoritmo Genético. A continuación se describen los parámetros de cada uno de éstos.

3.3.1 Parámetros de la Red Neuronal Artificial implementada

Como sistema de clasificación se implementó una Red Neuronal con una arquitectura de un perceptrón multicapa. La estructura del perceptrón puede ser vista como una matriz de adyacencias en la que cada columna representa las conexiones de una neurona con las demás. La ausencia o presencia de la conexión es indicada mediante los valores binarios 0 y 1. Sin embargo, si se consideran números reales, éstos pueden representar el peso o grado de la conexión entre cada una de las neuronas; en la figura 3.9 se esquematiza dicho concepto. Además de considerarse los pesos de las conexiones, el sesgo o umbral de la Red Neuronal puede ser visto como una neurona extra que alimenta a las entradas, a las neuronas ocultas y las neuronas de salida, anexándose a la matriz de adyacencias como la neurona inicial.

En la tabla 3.3 se muestran resumidas las principales características de la arquitectura de la Red Neuronal. Como se observa la Función de Activación empleada es una tangencial hiperbólica que es descrita a través de la ecuación:

$$f(a) = \tanh(a) = \frac{e^a - e^{-a}}{e^a + e^{-a}} \quad (3.22)$$

Esta función es una transformación lineal de la función sigmoïdal. Sin embargo, la función tangencial hiperbólica, en general, suele presentar mejores resultados en el entrenamiento y tiempo de convergencia.

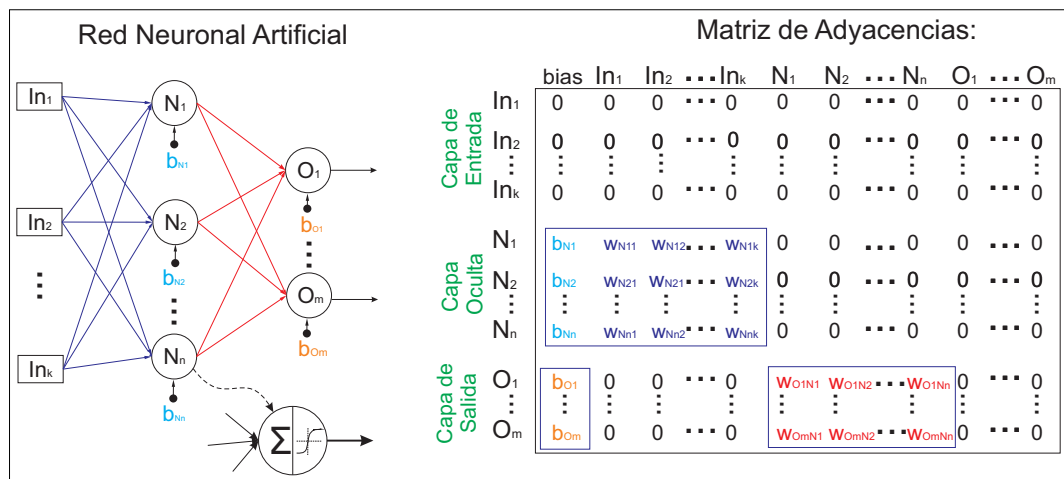


Figura 3.9: Representación de la Red Neuronal como una matriz de adyacencias

Tabla 3.3: Parámetros de la Red Neuronal Artificial

Datos	Entradas	Función de Activación	No. de neuronas Capa Oculta	Salidas
Laboratorio	-5 Componentes Principales -3 Momentos Estadísticos -4 Características Oscilatorias -Suma de Autocorrelación	Tangencial Hiperbólica	6; 10; 15	4
Quemadores	-4 Componentes Principales -1 Momentos Estadísticos -4 Características Oscilatorias -Suma de Autocorrelación -Entropía de la energía Wavelet -Entropía del Espectro de Potencia -Exceso de Aire lado A -Exceso de Aire lado B -Presión del Combustible	Tangencial Hiperbólica	6,10	5

El modelo de entrenamiento es un modelo supervisado por lo cual se requiere asignar valores de las salidas deseadas a los patrones de entrenamiento. Los valores asignados a cada patrón son mostrados en la figura 3.10. En esta figura se incluyen tanto los patrones de laboratorio como los del proceso de combustión en los quemadores.

3.3.2 Codificación de la Red Neuronal Artificial

Partiendo de la representación de la matriz de adyacencias se puede realizar la codificación de los pesos de la Red Neuronal a través de la concatenación de las filas de la matriz. Esta representación se esquematiza en la figura 3.11, en la que se obtienen dos cadenas representando las conexiones de los pesos de la capa oculta y las conexiones de los pesos de la capa de salida, que unidos conforman




Figura 3.10: Patrones de salida de la Red Neuronal

el cromosoma empleado en el Algoritmo Genético.

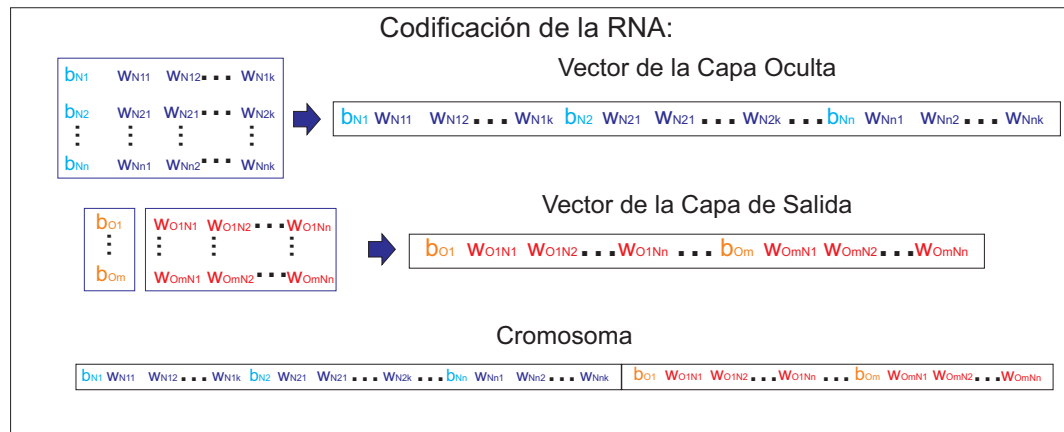


Figura 3.11: Codificación de la Red Neuronal

Problemas asociados con la codificación en las Redes Neuronales están presentes debido a las permutaciones de los pesos. Es decir, pueden existir conjuntos de pesos que sean soluciones simétricas equivalentes que proporcionan la misma salida de la neurona. Por otra parte, también se pueden encontrar dificultades debido a las funciones de transferencia. En una función de transferencia del tipo sigmoideal con las mismas entradas, la salida de una neurona será igual a la obtenida de forma normal, si se invierte el signo de todos los pesos y el resultado se multiplicado por -1:

$$F(a) = F(In_1 \cdot w_1 + In_2 \cdot w_2 + \dots + In_n \cdot w_n) \quad (3.23)$$

$$F(a) = -F(In_1 \cdot (-w_1) + In_2 \cdot (-w_2) + \dots + In_n \cdot (-w_n)) \quad (3.24)$$

3.3.3 Modelo del Algoritmo Genético implementado

Se implementó un Algoritmo Genético con representación real para el entrenamiento de la Red Neuronal descrita en la sección anterior. El algoritmo consiste de un modelo elitista con selección por ruleta en el cual se probaron diferentes tipos de cruza (descritas en la sección 2.7.4). Además, en el algoritmo se incluye un operador que permite explorar la arquitectura de la red eliminando conexiones de ésta.

A continuación se muestra el pseudocódigo del algoritmo desarrollado para el entrenamiento de la Red Neuronal:

Algoritmo 1 Pseudocódigo para el entrenamiento de una RNA con un AG

Entrada: Tamaño de la población N , Número máximo de generaciones G

Salida: Red Neuronal Artificial Entrenada

- 1: Cargar características extraídas de la señal.
 - 2: Verificar Normalización de características.
 - 3: Dividir aleatoriamente las señales de la base de datos en: Entrenamiento, Validación y Prueba.

 - 4: Inicializar población P_i de N individuos:
 - 5: $k = 1$
 - 6: **repetir**
 - 7: Generar pesos aleatorios de la matriz de adyacencias de la RNA_k .
 - 8: Implementar la eliminación de conexiones de las neuronas con un probabilidad 0.35.
 - 9: Concatenar los pesos de la matriz de adyacencias para forma el cromosoma.
 - 10: $k = k + 1$
 - 11: **hasta que** $k = N$
 - 12: $i \leftarrow 0$
 - 13: **repetir**
 - 14: Evaluar población P_i .
 - 15: Implementar selección por ruleta
 - 16: Aplicar operador de cruza. Generar Hijos P'_i .
 - 17: Aplicar operador de eliminación de conexiones P'_i con una probabilidad $\frac{P_{mut}}{2}$.
 - 18: Aplicar operador de mutación P'_i .
 - 19: Aplicar elitismo $P_{i+1} \leftarrow P'_i$
 - 20: $i \leftarrow i + 1$
 - 21: **hasta que** Condiciones de paro sean alcanzadas
-

Las características principales del modelo se presentan en la tabla 3.4.

Tabla 3.4: Características del Algoritmo Genético implementado

Característica	Tipo	Parámetros
Población	50 Individuos	
Elitismo	Mejor individuo	
Selección	Ruleta	
Cruza	Aritmética 2 puntos Uniforme Simulated Binary Crossover (SBX)	$a = 0.6$ $n_c = 5$
Mutación	Uniforme	$P_m = 0.035$
Función de Aptitud	ver Sec.3.3.3.1	valor optimo=1
Eliminación de conexiones	ver Sec.3.3.3.5	$P_{elim} = 0.5 \cdot P_m$
Criterio de paro	Generaciones máximas Valor óptimo de la función de Aptitud	
Rango de búsqueda de pesos	[-1000, 1000]	

A continuación se describen las características y parámetros de los operadores usados en el algoritmo.

3.3.3.1 Función de aptitud

Como se menciona en la sección 2.7.1, para la implementación del algoritmo es necesaria la definición de una función que asigne un valor a cada una de las posibles soluciones de acuerdo a su grado de aptitud. Un problema usual en el entrenamiento de Redes Neuronales son las condiciones y el momento de paro, de forma tal, que la red logre adquirir la habilidad de reconocer nuevos patrones sin que sea sobreentrenada. Métodos clásicos de entrenamiento de Redes neuronales como el de retropropagación usan el error cuadrático para ajustar los valores de los pesos. Se han desarrollado modelos de entrenamiento basados en Algoritmos Genéticos y combinaciones de retropropagación y Algoritmos Genéticos que siguen este enfoque. Algunos otros han buscado explotar las características propias de los Algoritmos Genéticos definiendo funciones de adaptación que además incluyen otros parámetros de optimización en aras de mejorar el entrenamiento de las Redes sin llegar al sobreentrenamiento.

Siguiendo este concepto, en esta tesis se definió una función de aptitud con la cual se buscan los pesos que mejor se ajustan a los datos de entrenamiento mientras se mantiene el mayor porcentaje de clasificación en los datos de validación, quedando definida la función a través de la fórmula:

$$F = \left\| \prod_{i=1}^n \left(\frac{e_i^2}{e_{max}^2} + 1 \right), 100 \cdot E_{valid} \right\| + \sqrt{\sum_{i=1}^n e_i^2} \quad (3.25)$$

Donde:

e_i =Error asociado a los datos de entrenamiento del patrón i

E_{valid} =Porcentaje de clasificación incorrecta del patrones de validación

e_{max} = Máximo error posible de clasificación

n =Tamaño del conjunto de datos de entrenamiento

Esta ecuación incluye el error cuadrático así como el producto de éste, lo cual permite discriminar las mejores soluciones al asignar valores muy altos a los elementos que peor ajustan el conjunto de entrenamiento. Además, incluye también un factor del porcentaje de clasificación de los patrones de validación. Un análisis de esta función muestra que el mejor elemento hallado será el que tenga un valor $F = 1$, es decir aquél con el menor porcentaje de clasificación incorrecta de los patrones de validación y con un error cuadrático igual a 0, con lo que el término $\prod_{i=1}^n \left(\frac{e_i^2}{e_{max}^2} + 1 \right)$ resulta en un valor igual a 1.

En la función definida se realiza la normalización $\frac{e_i^2}{e_{max}^2}$, que evita que el factor $\prod_{i=1}^n \left(\frac{e_i^2}{e_{max}^2} + 1 \right)$ resulte en valores extremadamente altos. Sin embargo, si el conjunto de datos de entrenamiento es grande, el valor podría resultar a su vez muy elevado o incluso superar la precisión del sistema.

3.3.3.2 Selección

Se usó un tipo de selección por Ruleta que es descrito mediante el siguiente pseudocódigo:

Algoritmo 2 Selección por Ruleta

Entrada: Función de Aptitud F_i de las n RNA's

- Calcular el valor esperado de cada individuo V_i
 - 2: Calcular la suma del valor esperado total V_t
 - $k = 1$
 - 4: **repetir**
 - $j = 1$
 - 6: Generar un número aleatorio $r \in [0, V_t]$
 - $S = 0$
 - 8: **repetir**
 - $S = S + V_j$.
 - 10: $j = j + 1$
 - hasta que** $S > r$
 - 12: $k = k + 1$
 - hasta que** $k = n$
-

3.3.3.3 Cruza

Se implementaron 4 diferentes operadores de cruza con la finalidad de evaluar y comparar el desempeño de cada uno de éstos, los cuales corresponden a los definidos en la sección 2.7.4: Cruza con dos puntos, cruza Aritmética, cruza SBX y cruza Uniforme.

Los parámetros de la cruza Aritmética y SBX son mostrados en la tabla 3.5

Tabla 3.5: Parámetros de los tipos de cruza

Tipo de cruza	Parámetro
Aritmética	$a = 0.6;$
SBX	$n_c = 5$

3.3.3.4 Mutación

Se definió el operador de mutación basado en la mutación uniforme de la sección 2.7.5:

$$P' = \langle v_1, \dots, v'_k, \dots, v_m \rangle \quad (3.26)$$

con

$$v'_k = \begin{cases} v_k + (u \cdot r \cdot (L_s - L_i) + r \cdot L_i) & \text{si } v_k + (u \cdot r \cdot (L_s - L_i) + r \cdot L_i) \in [L_i, L_s], \\ v_k - (u \cdot r \cdot (L_s - L_i) + r \cdot L_i) & \text{en otro caso.} \end{cases} \quad (3.27)$$

Donde:

u es un número aleatorio $\in (L_i, L_s)$, $r=0.25$ y $[L_i, L_s]$ es el rango de los valor que v_k puede tomar.

A través de la definición de este operador de mutación se pretende explorar el espacio de búsqueda haciendo modificaciones dentro de un rango pequeño del valor de los pesos. Se usó una probabilidad de mutación $P_m = 0.035$.

3.3.3.5 Eliminación de conexiones

Se implementó un operador que permitiera explorar la arquitectura de la red eliminando así conexiones de los pesos. Partiendo de la matriz de adyacencias de la sección 3.3.1, el operador sustituye el valor del peso por un 0 con una probabilidad P_{elim} . La aplicación de operador es esquematizada en la figura 3.12. Este operador es aplicado en la creación de la población inicial con una probabilidad de 0.35 permitiendo generar estructuras con diferentes conexiones. Posteriormente, el operador es aplicado a los descendientes de la cruce con una probabilidad de $0.5 \cdot P_{mut}$ permitiendo a la mutación ser el principal operador de exploración del espacio de búsqueda.




Figura 3.12: Operador de eliminación de conexiones

Capítulo 4

Resultados

Esta sección se muestran los resultados del algoritmo de entrenamiento descrito en la sección 3. Las pruebas abarcan un análisis del comportamiento de la Función de aptitud y los resultados obtenidos del entrenamiento de la Red Neuronal con datos de laboratorio y datos de un proceso real de combustión en una unidad de quemadores. Se incluyen además pruebas con diferentes tipos de cruza para los Algoritmos Genéticos, así como Arquitectura de Redes Neuronales con diferente número de neuronas en la capa oculta.

Se incluyen también las pruebas iniciales con un Algoritmo Genético para la evolución de diferentes arquitecturas en conjunto con el entrenamiento de una RNA.

4.1 Comportamiento de la función de aptitud

En la figura 4.1 se muestran los resultados del comportamiento de la Función de aptitud del mejor individuo hallado en pruebas correspondientes a datos de flamas de laboratorio con el Algoritmo Genético descrito en la sección 3 e implementando una cruza Aritmética Total usando la arquitectura de una Red Neuronal con 6 neuronas en la capa oculta.

En la figura 4.1(a) se observa un comportamiento escalonado en la Función de aptitud, mientras que en la figura 4.1(b) se presenta un comportamiento en el que los valores decrecen rápidamente en las primeras 25 generaciones, volviéndose luego más lenta la aproximación al valor óptimo (Función de aptitud=1). En la figura 4.1(c) se muestra un comportamiento en el que prevalece el mejor individuo durante varias generaciones, hasta que se halla una combinación que lo supera y la población comienza la convergencia hacia otro punto. Por su parte, en la figura 4.1(d) se presenta una combinación del comportamiento observado en las figuras 4.1(b) y 4.1(c) .

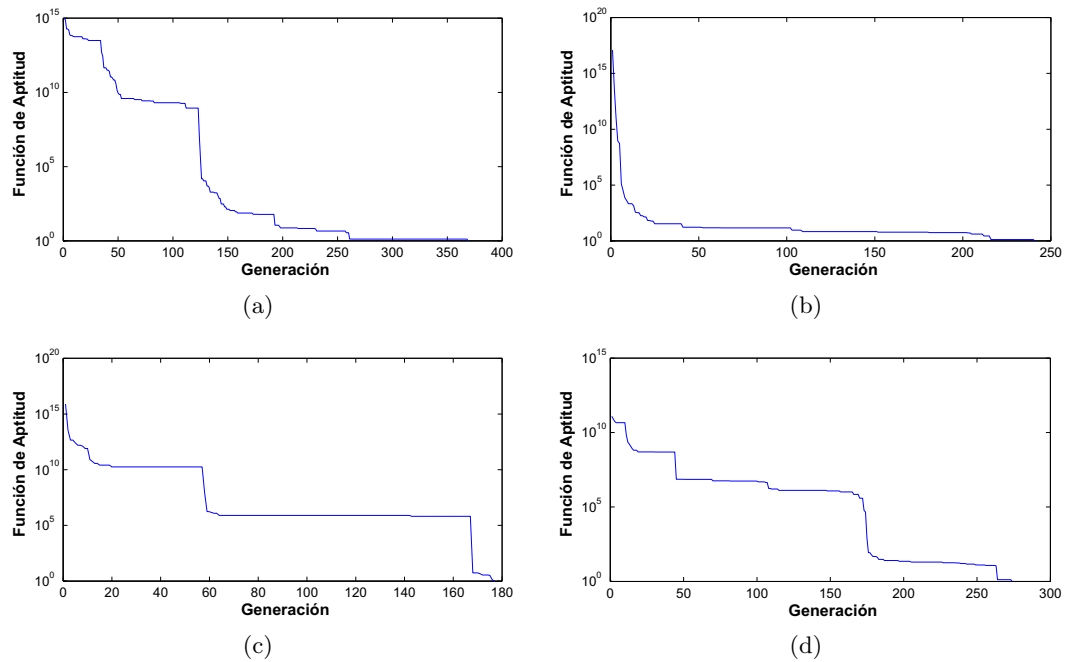


Figura 4.1: Comportamiento de la función de aptitud

En general, el patrón observado por la Función de aptitud en las pruebas fue el mostrado en las figuras 4.1(a) y 4.1(c). Como se puede apreciar, el algoritmo converge en un valor cercano al óptimo en pocas generaciones.

En la figura 4.2 se observan los resultados de diversas corridas del algoritmo de entrenamiento empleando como Función de aptitud la Ec. 3.25 (azul) y del Error Cuadrático (rojo) como Función de aptitud. El número de generaciones usando la ecuación 3.25 para alcanzar el valor óptimo es menor que al emplear el error cuadrático. En el mejor de los casos el uso del error cuadrático se comporta como el promedio de la ecuación 3.25.

Comparando los resultados de clasificación con ambas funciones se puede ver que el desempeño de la función definida por la Ec. 3.25 presenta un mayor porcentaje de clasificación de los patrones de prueba (tabla 4.1), requiriéndose también un menor número de generaciones en promedio.

Tabla 4.1: Comparación de la función de aptitud: Ec. 3.25 y error cuadrático

Función de aptitud	Generaciones promedio	% Clasificación			MSE promedio
		Entrenamiento	Prueba	Total	
Ec. 3.25	485.833	99.958	99.472	99.833	0.025
Error Cuadrático	1257.24	95.71	96.45	95.06	0.210




Figura 4.2: Comparación de la Ec. 3.25 vs error cuadrático como función de aptitud

4.2 Clasificación de las señales de laboratorio

Se realizaron pruebas con diferentes operadores de cruce (Sec. 2.7.4). Los resultados correspondientes a corridas de 30 pruebas en cada caso, son mostrados en la tabla 4.2. Las pruebas se realizaron con arquitecturas de RNAs de 10 neuronas en la capa oculta y se usaron como criterios de paro del algoritmo de entrenamiento, el mínimo de la Función de aptitud o al alcanzar un máximo de 1500 generaciones.

En todos los modelos de cruce se obtuvo un porcentaje de clasificación cercano al 100 % en el entrenamiento y validación, mientras que con nuevos datos de prueba los modelos de cruce Aritmética Total y Simulated Binary Crossover (SBX) obtuvieron los mayores porcentajes de clasificación.

Estos resultados no muestran una diferencia entre diferentes tipos de cruce. En estos casos también el porcentaje de datos clasificados con un error menor a 1×10^{-5} fue mayor que en el de los otros dos modelos.

Tabla 4.2: Resumen del entrenamiento con diferentes tipos de cruce (Datos de laboratorio)

Cruce	Generaciones promedio	% Clasificación			MSE promedio	% pruebas con $MSE < 1 \times 10^{-5}$
		Entrenamiento	Prueba	Total		
2 Puntos	412.600	99.958	99.028	99.715	0.020	36.67
Aritmética	485.833	99.958	99.472	99.833	0.025	56.67
SBX	637.767	99.917	99.306	99.757	0.016	40
Uniforme	426.867	99.958	99.194	99.715	0.019	40

En la figura 4.3 se muestran los resultados de una corrida con cruce Aritmética Total con 6 neuronas en la capa oculta. Se observa que la gráfica de la función de aptitud presenta una correlación inversa con la gráfica del porcentaje de clasificación del mejor elemento, siendo éste el comportamiento deseado del Algoritmo Genético: un menor valor de la Función de aptitud debe maximizar el porcentaje de clasificación y generalización.




Figura 4.3: Entrenamiento con cruce Aritmética Total

Otras pruebas realizadas consistieron en el análisis del número de neuronas en la capa oculta. Para ello, se consideraron los mismos tipos de cruce y se probaron con 6, 10 y 15 neuronas. En la tabla 4.3 se muestran los porcentajes de clasificación obtenidos.

Tabla 4.3: Cruce Aritmética: Pruebas con diferentes neuronas en la capa oculta

Cruza	Neuronas	Generaciones promedio	% Clasificación			MSE promedio	% pruebas con MSE < 1×10^{-5}
			Entrena	Prueba	Total		
2 puntos	6	399.900	99.972	99.278	99.778	0.016	43.33
	10	412.600	99.958	99.028	99.715	0.020	36.67
	15	609.833	99.688	99.986	98.944	0.023	26.67
Aritmética	6	492.23	99.93	98.944	99.65	0.0247	43.33
	10	485.833	99.958	99.472	99.833	0.025	56.67
	15	624.967	99.778	98.611	99.444	0.036	30
SBX	6	551.130	100	99.138	99.770	0.018	56.670
	10	637.767	99.917	99.306	99.757	0.016	40
	15	627.200	99.694	98.333	99.354	0.039	16.667
Uniforme	6	405.130	100	99.306	99.785	0.016	53.33
	10	426.867	99.958	99.194	99.715	0.019	40
	15	333.667	100	98.861	99.708	0.022	30

Los resultados con diferente número de neuronas no mostraron cambios significativos en el porcentaje de clasificación de nuevos datos con ninguno de los tipos de cruza, viéndose afectado solamente el número de generaciones promedio en el cual se alcanza el valor óptimo. En las pruebas de cruza, se puede observar que para la cruza Aritmética, SBX y en 2 puntos, existe, en general, una tendencia a incrementarse o mantenerse dentro del mismo rango el número de generaciones, conforme se incrementa el número de neuronas. Sin embargo, en el caso de la cruza uniforme, el promedio de generaciones en las pruebas con 15 neuronas disminuyó en comparación con las pruebas para 6 y 10 neuronas.

Basándose en estos resultados, se puede establecer que el desempeño del entrenamiento de la Red Neuronal con el Algoritmo Genético se ve afectado solamente en el número de ciclos, al establecerse diferente número de neuronas de la capa oculta, siendo una buena elección un número menor o igual a 10 neuronas.

4.2.1 Representación de la matriz de adyacencias como imagen

Con la finalidad de observar a más detalle el comportamiento de cada uno de los resultados de las pruebas con diferentes cruza, se realizó una codificación de la matriz de adyacencias mediante una representación como imagen considerando el rango de los valores posibles de los pesos y asociándolos a una trama de colores.

A continuación se presentan los resultados del entrenamiento de una RNA con 10 neuronas en la capa oculta utilizando dicha representación en algunos puntos de interés a través de las generaciones.

Pesos de la RNA entrenada con cruza en 2 Puntos

Capa Oculta	0	-38.849	0	0	339.598	0	177.027	0	-98.854	0	0	65.149	-53.824	135.851
	0	0	-27.243	0	0	-43.675	168.358	-148.742	796.629	0	-6.639	0	-286.208	0
	828.306	-545.403	0	208.936	31.142	183.581	0	-163.333	0	-215.759	-4.686	0	0	-139.794
	0	0	0	875.669	-649.074	-75.468	91.218	0	-864.220	0	122.275	0	0	0
	919.305	210.301	0	-708.125	68.589	0	0	0	0	0	745.511	0	747.206	280.465
	208.647	-469.003	973.743	-119.014	0	-153.109	-98.932	-119.021	-38.257	0	0	155.995	0	0
	86.195	0	0	0	0	0	0	0	710.403	-351.198	0	-150.875	0	0
	0	0	0	180.657	0	0	328.882	0	-128.184	0	168.988	135.629	87.912	0
	237.092	0	-228.272	0	-109.553	0	0	-388.431	0	349.166	-826.251	0	0	0
	-26.916	0	0	-97.771	-332.905	0	0	-431.407	0	-202.215	327.103	0	0	-145.149
Capa de Salida	$\begin{bmatrix} -991.077 & -24.823 & 78.106 & 0 & 357.927 & -718.591 & 76.207 & 0 & 0 & 870.687 & 0 & 0 \\ 0 & 0 & 0 & -270.590 & -756.114 & 0 & -1.774 & 0 & -803.321 & 202.892 & 0 & 0 \\ -130.328 & -70.964 & 0 & -285.373 & 131.471 & 140.728 & 0 & -303.367 & 53.758 & -99.351 & 22.892 & 0 \\ 109.642 & 942.697 & 0 & -822.681 & 0 & -211.167 & 0 & 151.589 & 48.576 & -778.461 & 0 & 0 \end{bmatrix}$													

Como se observa, el comportamiento de la cruza en 2 puntos y uniforme (figs. 4.4 y 4.7) es muy similar, mientras que el de la cruza Aritmética y SBX (figs. 4.5 y 4.6) a su vez presentan similitudes entre sí. El comportamiento de la cruza con dos puntos y uniforme tiende a preservar y propagar las conexiones eliminadas (color blanco) y los valores extremos, mientras que la cruza Aritmética y SBX combinan en forma gradual los pesos a través de las generaciones hasta llegar a valores de bajo orden (colores anaranjado claro y amarillo) preservando sólo algunos de los valores altos de las primeras generaciones.

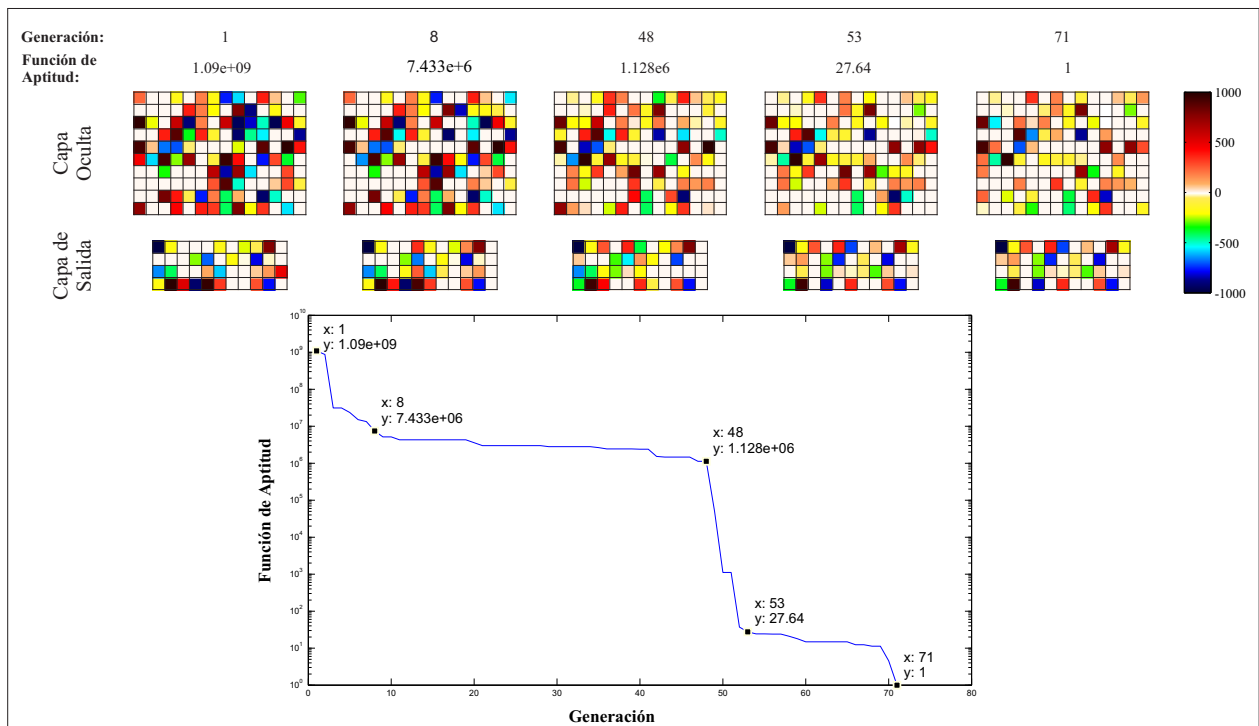


Figura 4.4: Evolución de las matrices de pesos: Cruza en 2 Puntos

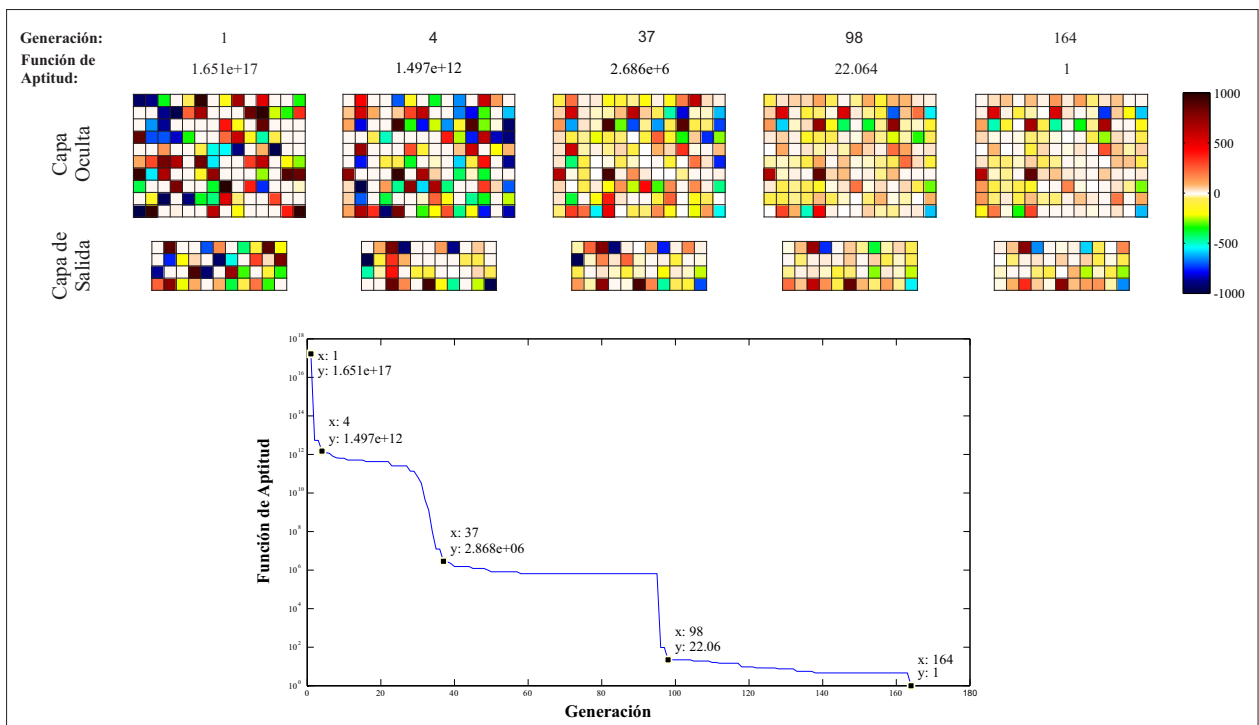


Figura 4.5: Evolución de las matrices de pesos: Aritmética Total

Estos resultados obtenidos con las pruebas de las señales de laboratorio indican que el Algoritmo Genético desarrollado es capaz de entrenar la Red Neuronal para la clasificación de los cuatro

Pesos de la RNA Entrenada con cruza Aritmética Total

Capa Oculta	-3.455	31.157	66.135	1.303	69.473	10.825	132.937	18.129	118.716	-48.250	22.720	58.847	0.607	-3.735
	6.536	527.642	5.700	-84.998	-31.124	-7.514	541.308	27.261	0	-20.781	-738.820	57.564	-196.170	-589.010
	111.100	-484.882	-123.415	-5.879	672.221	-76.741	-472.416	-0.733	-350.402	-36.589	663.201	3.815	-0.399	-176.131
	42.621	-14.204	1.551	-16.204	-50.512	-37.742	-17.632	-11.457	2.249	-68.096	-263.772	27.596	5.970	-74.421
	-5.798	81.556	-10.413	0	-90.682	40.098	-0.606	-15.858	21.507	-0.677	271.137	64.823	-27.754	44.818
	20.059	-43.233	-43.763	-26.031	50.445	-57.242	-36.111	0.072	-17.533	-1.779	-7.842	59.250	62.320	-68.931
	644.017	-22.769	-40.453	-1.534	852.581	34.091	66.540	12.292	4.069	-1.058	53.199	4.099	3.766	17.133
	135.623	-88.767	-41.482	-77.336	-141.973	-4.758	3.763	174.077	-15.232	-7.316	-1.339	26.642	-40.541	-285.983
	130.335	-44.757	16.747	-67.782	71.214	-38.728	-44.521	11.645	66.481	17.336	-2.492	196.283	-0.373	92.050
	-161.090	197.446	-12.132	-334.486	298.946	-0.407	-0.278	-1.168	10.477	-15.139	0	26.977	-5.160	-606.237
Capa de Salida	5.269	61.833	763.957	-648.484	-3.706	-14.255	6.640	-578.295	-54.361	-3.986	168.537			
	-7.554	-48.440	4.597	22.179	-1.675	45.373	0.665	44.372	-74.178	-14.451	-71.983			
	-20.861	2.348	-0.256	-43.756	-81.398	-11.717	77.846	-248.286	-25.375	-77.487	-262.957			
	-15.382	87.637	351.310	51.520	-11.886	750.148	71.791	116.430	143.583	-29.718	-649.080			

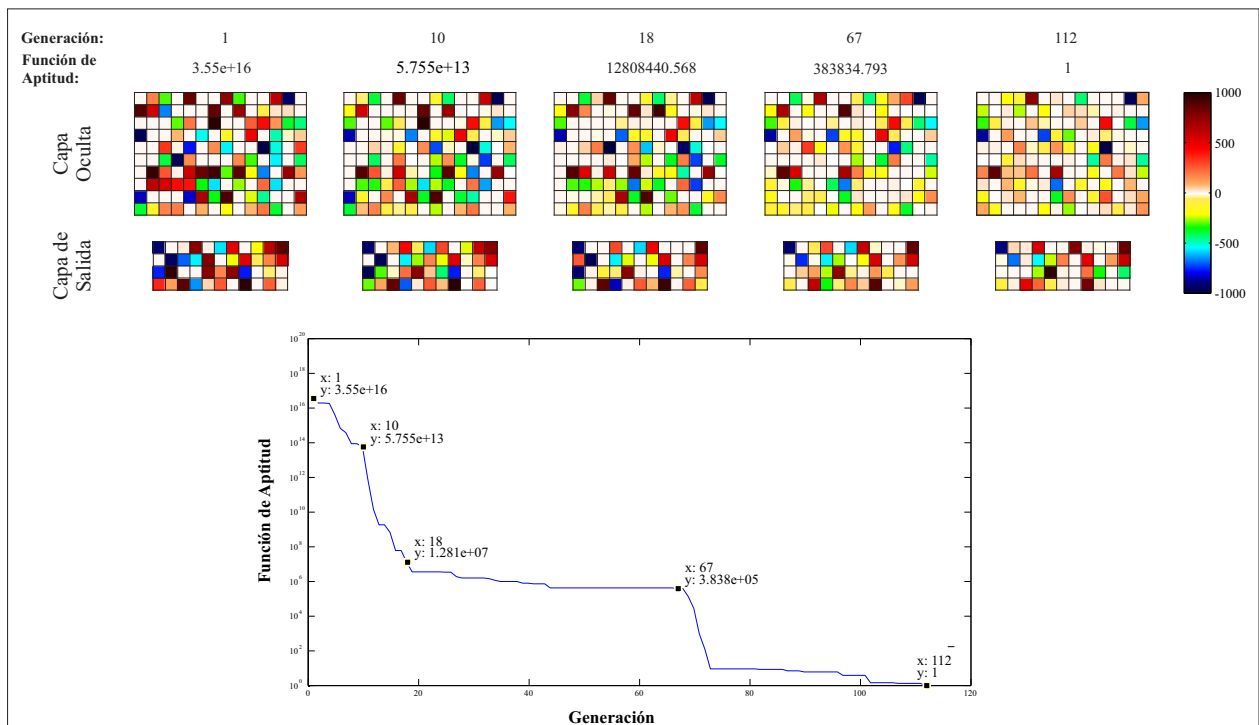


Figura 4.6: Evolución de las matrices de pesos: Cruza SBX

estados. Además, estos resultados indican que la Función Aptitud definida por la Ec. 3.25 permite hallar un conjunto de pesos cercano al óptimo en un menor número de generaciones que al usarse solamente el error cuadrático.

Pesos de la RNA Entrenada con cruza SBX

Capa Oculta	-0.660	0.640	-208.441	-109.002	755.846	0.099	23.895	0.042	-431.545	0.062	-0.407	0.017	-960.411	103.996
	-244.953	-6.870	13.684	-248.488	0	-211.024	-8.967	43.960	33.327	-31.421	-3.009	5.000	0.005	2.064
	-318.728	-85.610	5.558	-2.631	61.720	-31.442	-0.947	0.003	51.491	0.458	426.651	-10.542	-393.490	-634.358
	-853.570	-0.165	123.429	0	0	-725.405	-119.083	-289.568	-0.007	15.203	-49.343	-17.642	0.054	-6.357
	10.749	4.561	-0.196	179.224	-24.508	-74.407	144.389	-124.860	-0.522	-172.417	-982.487	-0.001	-24.172	-0.601
	-5.175	-4.582	-103.567	30.335	10.272	0	1.504	6.516	-11.257	-469.120	193.100	4.009	22.292	-465.961
	173.502	866.996	67.364	66.451	202.036	0.029	663.748	0.014	-1.105	-174.533	1.590	198.737	26.955	-240.932
	23.945	2.420	81.934	-144.937	-12.258	16.555	-685.915	0.436	-132.011	3.194	-172.958	-6.477	76.538	0.028
	-173.621	-11.390	23.949	79.989	-1.331	-1.004	-371.125	152.897	0.134	-136.649	273.134	-0.229	31.388	112.732
	100.969	-161.236	1.993	-0.238	-1.396	-193.826	10.260	-269.892	-9.391	6.778	29.601	-69.273	16.370	141.416
Capa de Salida	-886.389	35.367	12.689	535.660	0.229	0	776.244	6.179	-15.724	-0.105	838.666			
	-12.487	-676.980	14.315	-543.976	-242.162	182.534	2.684	495.617	-0.105	123.181	579.146			
	1.894	-0.311	0	-256.517	976.334	10.346	-1.085	214.848	-333.685	2.870	-424.963			
	-93.302	6.776	489.257	233.782	-80.380	18.856	-1.001	809.755	24.418	-0.815	1.470			

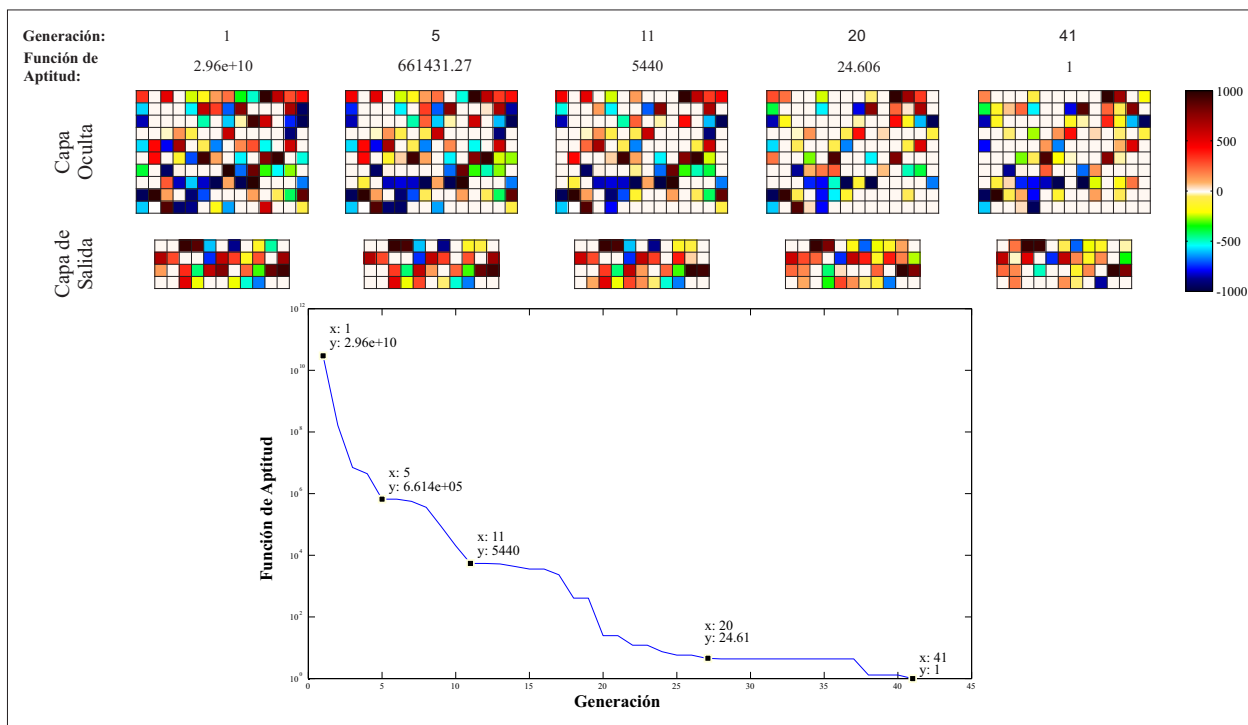


Figura 4.7: Evolución de las matrices de pesos: Cruza Uniforme

Pesos de la RNA entrenada con cruza Uniforme

Capa Oculta	175.008	0	0	0	-83.779	0	0	0	0	0	970.911	700.888	0	-207.186
	-392.738	-139.329	61.128	225.108	-550.561	0	0	-801.993	886.131	0	237.121	-63.802	772.235	0
	-835.531	-151.695	0	0	0	0	0	-150.670	-28.984	0	358.647	-155.738	-607.680	-950.373
	0	0	-43.626	0	-260.084	0	140.429	411.675	0	40.207	0	-50.571	0	-95.839
	-783.959	0	0	0	0	134.545	-660.870	0	0	0	0	83.247	516.866	0
	0	0	0	-278.869	-52.546	901.572	-212.638	-22.910	0	0	768.111	-27.635	0	0
	0	0	-859.779	8.478	0	248.160	0	0	-684.689	144.975	0	0	0	0
	0	-104.014	36.335	-753.737	-786.758	-832.765	-966.636	0	-984.311	-226.439	0	-176.282	203.336	0
	-949.276	979.050	-73.193	94.610	-786.353	0	-126.813	0	0	119.254	0	-51.388	0	0
	-586.918	0	0	34.867	-952.591	0	0	0	0	0	0	0	0	0
Capa de Salida	0	202.731	956.514	947.667	0	-59.338	-687.347	-221.548	-139.041	0	-29.572			
	613.470	-26.791	518.789	0	-741.278	600.187	167.858	-151.987	156.845	0	-343.421			
	225.980	167.589	0	-490.409	0	0	-133.715	166.877	0	966.129	782.959			
	0	185.889	0	0	0	145.113	-47.690	0	-855.407	0	0			

4.3 Clasificación de las señales de la unidad de quemadores

Los resultados del entrenamiento de la Red Neuronal con diferentes operadores de cruce usando las señales del proceso real, se muestran en la tabla 4.4.

Los porcentajes de clasificación corresponden al mejor resultado obtenido en 30 pruebas con cada tipo de cruce, teniendo como criterio de paro el mínimo de la función de aptitud o el alcanzar un máximo de 2000 generaciones.

Tabla 4.4: Clasificación con una RNA de 6 neuronas: Señales del proceso real

Cruce	% Clasificación			MSE promedio
	Entrenamiento	Prueba	Total	
2 Puntos	94.937	80.952	90.566	0.730
Aritmética	94.937	90.476	92.453	0.604
SBX	93.671	85.714	89.937	0.653
Uniforme	93.671	85.714	89.937	0.730

El mayor porcentaje de clasificación de los patrones de flama se obtuvo con la cruce Aritmética, clasificándose incorrectamente 4 de las 42 señales de prueba, que equivale a un porcentaje de clasificación correcta del 90.476%. La cruce uniforme y SBX presentan porcentajes del 85.714% correspondientes a una clasificación incorrecta de 6 señales de prueba. Como se puede observar, el porcentaje de entrenamiento en los 4 casos se encuentra cercano al 95%, lo que indica que bajo los criterios establecidos de paro no se logró hallar una solución que se ajuste completamente a los datos de entrenamiento, lo cual es corroborado por los valores del error cuadrático obtenidos.

Se muestran a continuación los pesos resultantes de la Red Neuronal de 6 neuronas en la capa oculta entrenada con una cruce Aritmética:

Pesos de la RNA de 6 neuronas entrenada con cruce Aritmética: Señales de unidad de quemadores

Capa Oculta	[246.556	-62.566	-11.492	0.947	31.812	1.827	11.485	0	-10.234	20.077	-29.839	9.529	24.386	-165.066	5.441	37.951]
	[486.339	-0.635	-391.634	629.521	29.751	-7.396	-6.967	6.004	117.715	21.543	-61.985	0	-4.847	5.082	14.409	-445.152]
	[12.939	-9.867	8.466	1.566	1.881	17.374	-2.691	0	67.564	-5.251	-3.918	-4.369	-40.306	144.137	125.500	24.500]
	[-19.544	-2.578	-332.662	0.391	22.435	117.762	-33.860	90.779	-12.081	-44.558	21.456	-19.782	201.056	-134.610	-22.280	31.996]
	[-102.801	46.142	27.050	109.997	41.979	-33.928	0.902	0.225	29.386	32.720	32.635	210.754	43.175	0.598	-8.372	7.871]
	[784.186	8.385	14.189	32.038	-129.646	166.981	1.142	0	10.605	-48.577	-38.853	79.009	116.626	17.629	-76.873	95.640]

Capa de Salida	[4.605	-16.083	40.635	36.740	256.175	110.853	-312.776]
	[-72.192	-23.924	94.947	133.433	-6.659	22.247	-0.257]
	[45.337	-108.223	4.949	-164.577	-93.785	8.944	-52.355]
	[9.834	159.995	-477.490	-131.852	-84.914	29.756	-49.711]
	[-32.976	13.783	59.243	-5.796	85.535	-46.344	-155.832]

A su vez, se realizaron pruebas de entrenamiento con 10 Neuronas. Los resultados obtenidos de la mejor RNA entrenada en 30 pruebas se muestran en la tabla 4.5. En este caso, el resultado de la cruce aritmética es comparado también con el entrenamiento, empleando el Error Cuadrático como Función de aptitud.

Tabla 4.5: Clasificación con una RNA de 10 neuronas: Señales de los quemadores

F. Aptitud	Cruce	% Clasificación			MSE
		Entrenamiento	Prueba	Total	promedio
Ec. 3.25	2 Puntos	89.873	73.810	86.164	0.830
Ec. 3.25	Aritmética	96.203	90.476	94.969	0.327
MSE	Aritmética	32.911	40.476	33.962	2.868
Ec. 3.25	SBX	92.405	88.095	91.824	0.553
Ec. 3.25	Uniforme	94.937	80.952	91.195	0.604

Nuevamente la cruza Aritmética presenta el mayor porcentaje de clasificación de las señales de prueba, siendo igual al obtenido con la red de 6 neuronas en la capa oculta (tabla 4.4). En el caso de la cruza SBX el porcentaje no cambió considerablemente, mientras que la cruza con 2 puntos y Uniforme presentaron una disminución del porcentaje de clasificación.

La comparación del porcentaje de clasificación empleando como función de aptitud la Ec. 3.25 es considerablemente mejor. Los resultados muestran que al emplearse únicamente el error cuadrático como función de aptitud no se logró clasificar los patrones de flama.

A continuación se presentan los pesos de la Red Neuronal obtenidos con el Algoritmo Genético.

Pesos de la RNA de 10 neuronas entrenada con cruza Aritmética: Señales de los Quemadores

Capa Oculta	-39.504	-29.120	145.739	29.077	-83.731	64.203	-94.214	-0.154	-16.496	84.658	31.317	-129.305	128.593	24.783	-12.451	-16.960
	-188.741	-16.486	-3.824	-19.889	285.728	-19.388	5.099	7.735	8.323	-79.395	-16.672	-30.173	17.869	-39.556	37.460	469.285
	81.654	58.077	341.384	-0.003	-0.703	0	-41.465	-23.155	47.936	-5.763	-22.778	-26.866	21.670	0	174.207	20.993
	-240.297	12.414	-32.222	-0.745	-21.399	15.464	75.561	-2.371	22.247	-16.242	-31.408	-3.068	13.155	-483.309	-37.900	-17.992
	-444.620	199.312	-19.575	6.728	28.859	104.805	22.154	-5.071	-5.047	24.892	-13.289	-35.088	-93.663	3.587	141.824	-4.311
	38.417	-7.325	237.413	0	-40.801	22.575	-54.866	-6.363	-24.118	81.847	-8.434	-125.625	-7.089	139.678	-8.224	-5.227
	736.957	89.851	6.165	-16.255	0.976	0.005	-26.949	-52.723	-12.905	16.430	2.541	42.175	-117.656	157.084	1.366	23.818
	-4.198	-5.465	-73.554	-13.430	37.157	86.126	-4.085	-5.007	106.039	-5.159	45.639	-14.780	2.576	269.208	221.681	12.736
	-35.888	-19.167	402.254	46.786	-97.654	-152.485	-20.397	0	-4.394	-42.333	-8.275	-19.077	30.734	-108.930	18.855	0
	-15.160	-4.982	-29.991	107.666	-78.797	14.950	-1.030	-2.777	-57.819	15.024	-0.067	12.752	-150.097	2.562	-89.035	-3.312
Capa de Salida	-0.019	126.660	113.883	14.700	81.479	9.770	-142.260	-185.465	-92.674	216.366	0.620					
	-18.232	63.926	-59.319	0	-13.486	6.977	-25.563	-113.271	192.733	7.481	2.721					
	-175.942	-4.060	-160.201	-0.143	-143.414	87.570	-43.844	-31.775	-134.068	-20.845	-0.007					
	-290.621	-92.420	432.302	0	-215.325	69.132	-6.247	-34.602	-24.238	-342.730	47.342					
	-15.177	-193.319	-334.899	-67.521	163.216	692.820	-37.757	-39.193	-16.438	-78.858	56.277					

En la figura 4.8 se presenta el proceso de entrenamiento a través del cual se determinaron los pesos de la red mostrada.

Si bien el entrenamiento no permitió encontrar una solución que satisficiera por completo el ajuste de todos los patrones, se tiene un alto porcentaje de clasificación, lo cual indica un alto grado de correlación entre las señales adquiridas y el proceso de la combustión. Cabe mencionar además que la propia complejidad del proceso de la combustión y el ruido presente en la señal originado por la radiación de las flamas próximas y de la misma refracción del horno son factores que impiden la clasificación completa de las señales.




Figura 4.8: Entrenamiento de la RNA con señales de la unidad de quemadores

4.4 Entrenamiento y evolución de la arquitectura

En la sección anterior se describen los resultados del entrenamiento de una Red Neuronal con una arquitectura de un perceptrón multicapa descrita en la Sección 2.6.1 y representada mediante una matriz de adyacencias mostrada en la figura 4.9. En la estructura de la Red implementada se hizo uso únicamente de las conexiones hacia las capas subyacentes. Sin embargo, este tipo de representación de una red permite hacer uso de arquitecturas más complejas, incluyendo conexiones entre las diversas capas y neuronas con conexiones recurrentes. En esta sección se presentan los resultados del entrenamiento de una red que permite las conexiones entre las diferentes capas. La figura 4.9 muestra un esquema de la red siguiendo la representación con la matriz de adyacencias.

Para la implementación del cromosoma del Algoritmo Genético y usando este modelo de Red Neuronal basta con la concatenación de todas las filas de la Matriz de Adyacencias, donde cada fila contiene los pesos de las conexiones existentes entre una neurona dada y todas las demás neuronas, incluyéndose las entradas que son consideradas a su vez como neuronas.

Una Red Neuronal de i entradas, j neuronas en la capa oculta y k salidas con una conexión total es representada mediante la matriz de adyacencias de la figura 4.10. En esta se tienen presentes las conexiones recurrentes y las conexiones entre capas.

Así, las salidas de cada una de las neuronas de este esquema de RNA están contenidas en el vector \mathbf{a} :

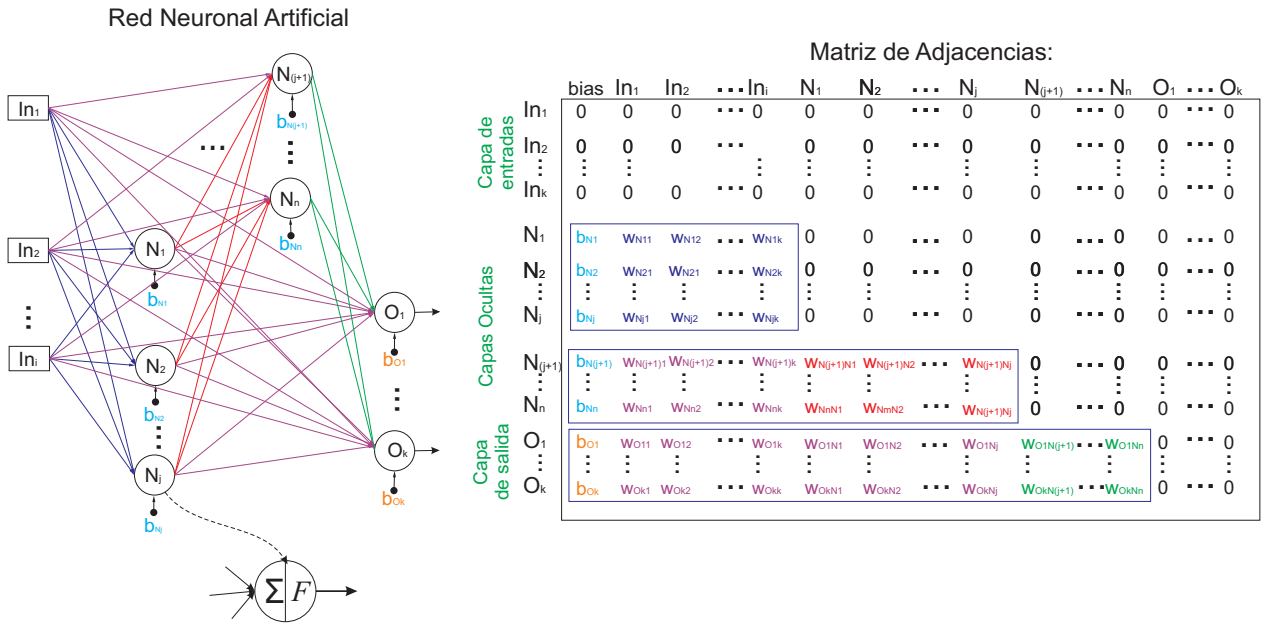


Figura 4.9: Representación de la RNA con conexiones entre capas mediante la matriz de adyacencias

	N ₁₁	...	N _{1i}	N ₂₁	...	N _{2j}	N ₃₁	...	N _{3k}
N ₁₁	w ₁₁₁₁	...	w _{111i}	w ₁₁₂₁	...	w _{112j}	w ₁₁₃₁	...	w _{113k}
⋮	⋮	⋮	⋮	⋮	...	⋮	⋮	...	⋮
N _{1i}	w _{1i11}	...	w _{1i1i}	w _{1i21}	...	w _{1i2j}	w _{1i31}	...	w _{1i3k}
N ₂₁	w ₂₁₁₁	...	w _{211i}	w ₂₁₂₁	...	w _{212j}	w ₂₁₃₁	...	w _{213k}
⋮	⋮	⋮	⋮	⋮	...	⋮	⋮	...	⋮
N _{2j}	w _{2j11}	...	w _{2j1i}	w _{2j21}	...	w _{2j2j}	w _{2j31}	...	w _{2j3k}
N ₃₁	w ₃₁₁₁	...	w _{311i}	w ₃₁₂₁	...	w _{312j}	w ₂₁₃₁	...	w _{313k}
⋮	⋮	⋮	⋮	⋮	...	⋮	⋮	...	⋮
N _{3k}	w _{3k11}	...	w _{3k1i}	w _{3k21}	...	w _{3k2j}	w _{2k31}	...	w _{3k3k}

Figura 4.10: Matriz de pesos de una RNA con conexiones completas

$$\mathbf{a} = \begin{bmatrix} a_{11} \\ \vdots \\ a_{1i} \\ a_{21} \\ \vdots \\ a_{1j} \\ a_{31} \\ \vdots \\ a_{3k} \end{bmatrix} = F(\mathbf{n}) = \begin{bmatrix} f(n_{11}) \\ \vdots \\ f(n_{1i}) \\ f(n_{21}) \\ \vdots \\ f(n_{1j}) \\ f(n_{31}) \\ \vdots \\ f(n_{3k}) \end{bmatrix} \tag{4.1}$$

donde \mathbf{n} es calculado mediante:

$$\mathbf{n} = \begin{bmatrix} x_{11} + \sum_{l=1}^i w_{111l} \cdot a_{2l}(t-1) + \sum_{m=1}^j w_{112m} \cdot a_{2r}(t-1) + \sum_{s=1}^k w_{113s} \cdot a_{3s}(t-1) \\ \vdots \\ x_{1i} + \sum_{l=1}^i w_{1i1l} \cdot a_{2l}(t-1) + \sum_{m=1}^j w_{1i2m} \cdot a_{2r}(t-1) + \sum_{s=1}^k w_{1i3s} \cdot a_{3s}(t-1) \\ x_{21} + \sum_{l=1}^i a_{2l} + \sum_{m=1}^j w_{212m} \cdot a_{2m}(t-1) + \sum_{s=1}^k w_{213s} \cdot a_{3s}(t-1) \\ \vdots \\ x_{2j} + \sum_{l=1}^i a_{2l} + \sum_{m=1}^j w_{2j2m} \cdot a_{2m}(t-1) + \sum_{s=1}^k w_{2j3s} \cdot a_{3s}(t-1) \\ x_{31} + \sum_{l=1}^i a_{2l} + \sum_{m=1}^j a_{2m} + \sum_{s=1}^k w_{313s} \cdot a_{3s}(t-1) \\ \vdots \\ x_{3k} + \sum_{l=1}^i a_{2l} + \sum_{m=1}^j a_{2m} + \sum_{s=1}^k w_{3k3s} \cdot a_{3s}(t-1) \end{bmatrix} \quad (4.2)$$

En forma compacta:

$$\mathbf{n} = \mathbf{W} \cdot \mathbf{a}^t + \mathbf{X} = \begin{bmatrix} x_{11} + W_{11} \cdot a^{t_1} \\ \vdots \\ x_{1i} + W_{1i} \cdot a^{t_1} \\ x_{21} + W_{21} \cdot a^{t_2} \\ \vdots \\ x_{2j} + W_{2j} \cdot a^{t_2} \\ x_{31} + W_{31} \cdot a^{t_3} \\ \vdots \\ x_{3k} + W_{3k} \cdot a^{t_3} \end{bmatrix} \quad (4.3)$$

con:

$$a^{t_1} = \begin{bmatrix} a_{11}(t-1) \\ \vdots \\ a_{1i}(t-1) \\ a_{21}(t-1) \\ \vdots \\ a_{1j}(t-1) \\ a_{31}(t-1) \\ \vdots \\ a_{3k}(t-1) \end{bmatrix}, \quad a^{t_2} = \begin{bmatrix} a_{11} \\ \vdots \\ a_{1i} \\ a_{21}(t-1) \\ \vdots \\ a_{1j}(t-1) \\ a_{31}(t-1) \\ \vdots \\ a_{3k}(t-1) \end{bmatrix}, \quad \dots \quad a^{t_n} = \begin{bmatrix} a_{11} \\ \vdots \\ a_{1i} \\ a_{21} \\ \vdots \\ a_{1j} \\ a_{31}(t-1) \\ \vdots \\ a_{3k}(t-1) \end{bmatrix} \quad (4.4)$$

Donde las salidas de la red neuronal en el ciclo t son: a_{31}, \dots, a_{3k} ; los valores de $x_{11} \dots x_{1,i}$ representan las i entradas, $x_{21} \dots x_{2,j}, x_{31} \dots x_{3,k}$ son los bias o umbrales de las neuronas, y las salidas

previas de las neuronas están representadas por $a(t - 1)$.

En el caso de la arquitectura de la RNA que se muestra en la figura 4.9, al no existir conexiones recurrentes, los valores previos $a(t - 1)$ son igual a cero.

Esta arquitectura fue probada con las señales de laboratorio, empleándose el Algoritmo Genético con los mismos parámetros descritos en las Sección 3.3.3, incluyéndose además la posibilidad de explorar la arquitectura con diferentes capas, considerándose como máximo 3 capas ocultas y un número no mayor de 15 neuronas por capa.

Los promedios de los resultados del entrenamiento y evolución obtenidos de 30 pruebas para cada tipo de cruce son mostrados en la tabla 4.6.

Tabla 4.6: Resultados de la clasificación con la RNA obtenida del AG con entrenamiento y evolución de arquitectura: Señales de laboratorio

Cruce	Generaciones	% Clasificación			MSE promedio
		Entrenamiento	Prueba	Total	
2 Puntos	692.000	99.931	99.194	99.694	0.017
Aritmética	745.933	99.556	98.139	99.021	0.047
SBX	872.533	99.417	97.889	98.944	0.056
Uniforme	837.900	99.667	98.194	99.264	0.039

Comparando los resultados obtenidos con la arquitectura fija mostrados en la tabla 4.2, los valores de clasificación son muy similares y cercanos al cien por ciento. Sin embargo, el número de generaciones promedio es considerablemente mayor en la evolución de la arquitectura. Un análisis más detallado mostró que el entrenamiento y evolución alcanza porcentajes de clasificación más altos en pocas generaciones, siendo un pequeño incremento en el porcentaje de clasificación el que toma el mayor número de generaciones. Esto es mostrado en la figura 4.11, donde se obtiene un porcentaje de clasificación cercano al 100% en menos de 50 generaciones, requiriéndose posteriormente más de 400 generaciones para mejorarlo.

Este comportamiento indica que el Algoritmo Genético logra discriminar correctamente entre soluciones malas y soluciones cercanas a la óptima, definida por la ecuación 3.25, siendo más tardada la búsqueda y selección del valor óptimo. En un sistema de clasificación, este comportamiento es útil al proporcionar un alto porcentaje de clasificación con un número reducido de ciclos de entrenamiento.




Figura 4.11: Entrenamiento y evolución de la arquitectura con Cruza Uniforme: Señales de laboratorio

Capítulo 5

Conclusiones y Recomendaciones

5.1 Objetivos alcanzados

Se realizó la obtención de señales de flama bajo condiciones controladas estableciéndose patrones en función de la relación aire combustible, con las cuales se generó una base de datos que serviría de prueba para la verificación del entrenamiento de la Red Neuronal mediante el Algoritmo Genético.

Se realizó el procesamiento y extracción de características de las bases de datos, que fueron empleadas para la caracterización de la combustión a través de la clasificación de patrones de flama.

Se implementó una arquitectura de una Red Neuronal Artificial y se planteó su representación mediante las matrices de adyacencias para poder ser usada en un Algoritmo Genético.

Se desarrolló un Algoritmo Genético definiéndose diferentes operadores para el entrenamiento de la Red Neuronal, para lo cual se definió también una función de aptitud a través de la cual se pudiera seleccionar el mejor elemento entrenado basándose en el error cuadrático y el porcentaje de señales de validación clasificadas correctamente. Se mostró que el Algoritmo Genético implementado con la función definida permite el entrenamiento de la Red Neuronal con la arquitectura establecida.

Finalmente, se realizó la adquisición de señales electromagnéticas de un proceso real de combustión de una unidad de quemadores, a las cuales se les hizo un análisis y extracción de características a través de las cuales y en conjunto con parámetros de la combustión se entrenó una Red Neuronal usando el Algoritmo Genético desarrollado para la caracterización de patrones de Flama de la combustión.

Además, se planteó un esquema de entrenamiento y evolución de la arquitectura de una Red Neuronal mediante Algoritmos Genéticos usándose la representación de la matriz de adyacencias y

se verificó el entrenamiento de una red con conexiones entre capas usando las señales de laboratorio, dejándose abierta la opción al entrenamiento de redes recurrentes.

5.2 Conclusiones

En el presente trabajo de investigación se realizó el desarrollo de un Algoritmo Genético empleado en la etapa de entrenamiento de una Red Neuronal Artificial para la caracterización de un proceso de combustión, usándose como entradas las características extraídas del espectro electromagnético de las flamas, como son momentos estadísticos, Componentes Principales, características oscilatorias, entropía y autocorrelación, así como parámetros de la combustión.

Los Algoritmos Genéticos presentan características que los hacen especialmente útiles en espacios como los presentes en la selección de pesos de una Red Neuronal.

Los resultados de las matrices obtenidas en las pruebas con las señales del laboratorio de la sección 4.2 muestran la existencia de diferentes conjuntos de pesos que satisfacen la función objetivo (Ec. 3.25). Parte de la dificultad de la solución mediante un Algoritmo Genético usado en el entrenamiento de la Red Neuronal es debido a las permutaciones de los pesos y a la propia función de transferencia, que pueden dar origen a mismas salidas en una neurona con diferentes combinaciones de pesos. El objetivo tras estos conceptos es aprovechar la posibilidad de hallar diferentes combinaciones que den solución al problema a través de una correcta selección de la codificación y del desarrollo de los operadores adecuados que permitan explotar las soluciones halladas a la vez que se pueda explorar el espacio evitando quedar atrapado en soluciones locales. Es decir, la codificación de las soluciones del problema y el desarrollo de los operadores están estrechamente ligados y son parte esencial en la solución del problema.

Por otra parte, en el desarrollo de un sistema de clasificación es de gran importancia el procesamiento de las señales y generación de las entradas o características a través de las cuales se pretende hacer la separación y clasificación de los patrones. En un sistema en el que se tengan las características ideales, éstas proveerán una clasificación por sí mismas. Por otro lado un sistema ideal de clasificación no requeriría de dicho procesamiento ni la extracción de características. En la mayoría de los casos prácticos ninguna de estas dos situaciones es posible por lo que la exitosa solución a un problema requiere un equilibrio entre el desempeño del sistema de clasificación (en este caso del modelo de la Red Neuronal usado) y las características extraídas. Los resultados obtenidos muestran que el algoritmo de entrenamiento es capaz de obtener un conjunto de pesos cercano al óptimo para la clasificación de las señales, lo cual indica que las características extraídas son útiles para el sistema de clasificación de los patrones de flama.

En cuanto al Algoritmo Genético las pruebas realizadas con las señales de laboratorio no mostraron diferencias significativas al emplearse diferentes tipos de cruza, mientras que el desempeño con las señales de un proceso real de combustión sí presentó algunas diferencias, siendo la cruza

Aritmética la que obtuvo mejores resultados. Esto muestra que bajo sistemas completamente clasificables, el Algoritmo Genético permite hallar buenas soluciones, mientras que en sistemas mucho más complejos, el desempeño se ve afectado por los operadores implementados.

Las flamas clasificadas de las señales de laboratorio mostraron que las características extraídas de la señal electromagnética de la flama proveen información sobre el estado de la combustión y pueden ser útiles en la caracterización de los patrones de flama y pueden servir para el seguimiento, monitoreo y control del proceso. Por otra parte, las señales del proceso de combustión de la unidad de quemadores fueron clasificadas correctamente con un porcentaje alto teniéndose en cuenta que la dinámica del proceso no presenta un comportamiento estable, además de haber considerables fuentes de ruido como la propia refracción del horno, lo que da como resultado un porcentaje de señales incorrectamente clasificadas.

Así, finalmente se puede decir que las características de la señal electromagnética pueden aportar información para la caracterización del proceso de la combustión a través de la identificación de los patrones de flama y que los sistemas como las Redes Neuronales en conjunto con los Algoritmos Genéticos son una opción viable en problemas de clasificación y que pudieran ser útiles en sistemas que requieren adaptarse automáticamente a las condiciones cambiantes.

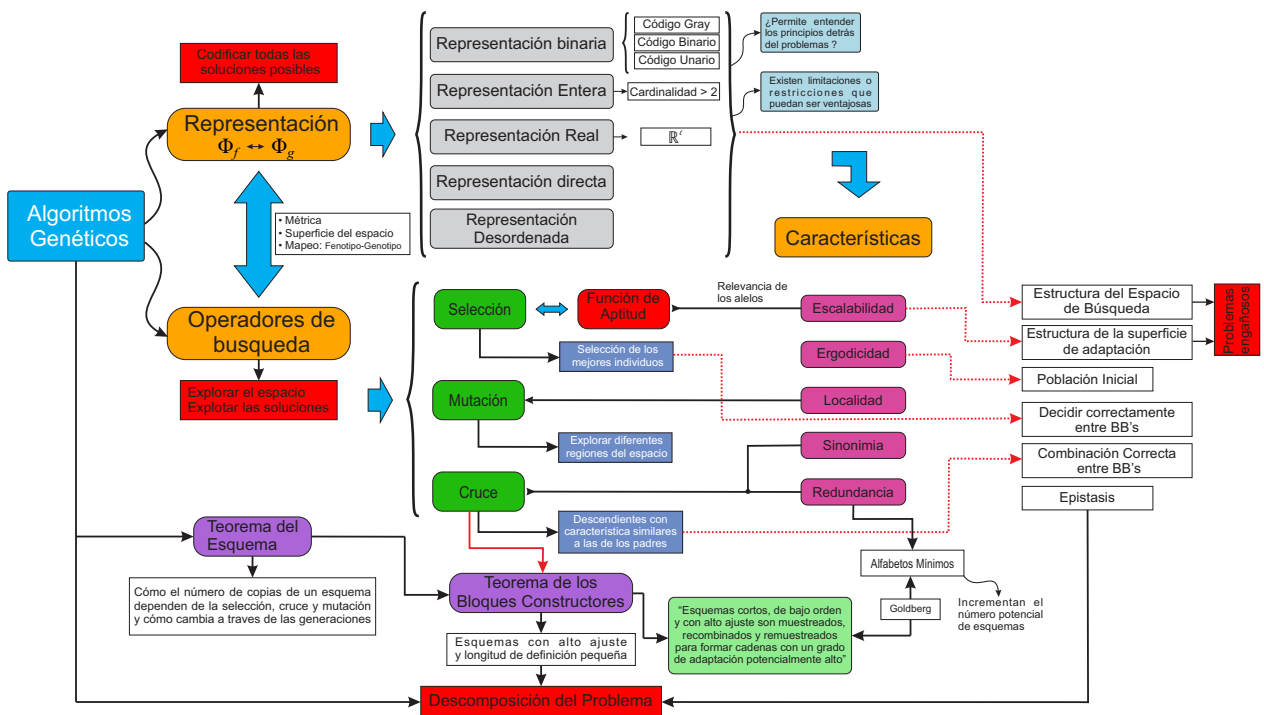
5.3 Recomendaciones y trabajo futuro

Como parte del trabajo futuro se recomienda un análisis de las señales y extracción de características en el dominio de la frecuencia, así como la implementación de una metodología para la selección automática de características que permita elegir y descartar características que pudieran estar correlacionadas o que aporten poca información. Esto, con la finalidad de determinar las mejores entradas que tengan relación con parámetros directos de la combustión, como por ejemplo el exceso de aire, flujo de combustible, temperatura de flama, entre otros.

Como trabajo futuro se considera el análisis y el uso de Algoritmos Genéticos con diferentes arquitecturas de Redes Neuronales incluyendo sistemas recurrentes y auto-adaptables así como el uso de metodologías como la evolución diferencial y sistemas de colonia de hormigas.

Apéndice A

Diagrama conceptual de un Algoritmo Genético



Apéndice B

Características extraídas de las señales de la unidad de quemadores

Patrón	Momento	Componentes Principales				Características Oscilatorias				Auto-corr.	Entropía		Parámetros Combustión		
	2^{do}	1	2	3	4	media periodo	media picos	s periodo	s picos		Ht	Hw	O2A	O2B	Flujo Comb.
1	0.207	0.478	0.410	0.116	0.270	0.668	0.418	-0.088	0.381	-0.228	0.389	0.117	-0.497	-0.513	0.194
2	0.370	0.336	0.316	-0.038	0.215	0.538	0.444	-0.305	0.099	-0.360	0.323	-0.017	-0.295	-0.286	0.221
3	-0.285	0.347	0.348	-0.120	0.135	0.218	0.241	-0.365	0.204	-0.092	0.584	0.302	-0.373	-0.307	0.222
4	0.651	0.583	0.571	0.069	0.460	0.327	0.306	-0.132	0.653	0.963	0.414	0.467	-0.298	-0.237	0.243
5	-0.504	0.340	0.164	0.126	0.275	0.056	0.013	-0.615	0.003	-0.193	0.422	0.235	-0.521	-0.457	0.234
6	-0.346	0.949	0.892	0.413	0.858	0.387	0.644	0.103	0.656	0.036	0.731	0.841	1.000	1.000	0.315
7	0.015	0.581	0.386	0.358	0.574	0.445	0.372	0.633	0.173	-0.479	0.559	0.239	0.360	0.365	0.287
8	0.897	0.922	0.819	0.480	0.893	0.185	0.529	-0.410	0.992	0.016	0.928	0.607	0.225	0.265	0.292
9	0.800	0.740	0.755	0.178	0.473	-0.102	0.463	-0.247	0.567	-0.080	0.667	0.461	0.555	0.574	0.314
10	-0.352	0.322	0.183	0.083	0.245	-0.055	0.288	-0.185	-0.206	-0.270	0.484	0.267	0.209	0.236	0.321
11	-0.122	0.765	0.705	0.288	0.635	0.275	0.301	-0.392	0.642	0.501	0.409	0.423	-0.122	-0.108	0.313
12	-0.055	0.598	0.477	0.272	0.396	0.406	0.303	-0.829	0.554	0.148	0.385	0.131	-0.213	-0.153	0.300
13	0.258	0.631	0.429	0.384	0.619	0.074	0.117	-0.245	0.374	0.456	0.462	0.013	-0.123	-0.002	0.309
14	-0.141	0.656	0.507	0.350	0.621	0.223	0.259	-0.158	0.483	0.255	0.632	0.302	-0.908	-0.958	0.277
15	-0.400	0.566	0.417	0.276	0.476	0.136	-0.047	-0.466	0.432	-0.030	0.361	0.232	-0.864	-0.957	0.272
16	0.194	0.416	0.330	0.116	0.332	0.056	0.213	-0.398	0.154	0.321	0.442	-0.086	-0.891	-1.000	0.286
17	-0.315	0.572	0.547	0.132	0.330	0.265	0.512	-0.239	0.296	0.283	0.560	0.294	-0.889	-0.939	0.436
18	-0.195	0.684	0.459	0.486	0.690	0.190	0.591	-0.259	0.242	-0.328	0.700	0.306	-1.000	-0.986	0.917
19	0.054	0.850	0.645	0.591	0.774	0.265	0.506	-0.156	0.631	0.174	0.471	0.987	-0.924	-0.915	0.906
20	0.736	0.826	0.668	0.506	0.761	0.643	0.517	-0.061	0.559	0.384	0.770	0.943	-0.864	-0.881	0.912
21	-0.406	0.887	0.564	0.822	0.876	0.409	0.387	-0.333	0.664	0.496	0.554	0.781	-0.915	-0.934	0.918
22	0.082	0.709	0.561	0.358	0.644	0.051	0.331	0.049	0.449	0.225	0.650	0.671	-0.530	-0.416	0.933
23	0.301	0.623	0.501	0.292	0.476	0.416	0.395	-0.046	0.715	-0.015	0.558	0.428	-0.555	-0.483	0.928
24	-0.109	0.897	0.664	0.678	0.903	0.083	0.657	-0.696	0.602	-0.051	1.000	0.769	-0.490	-0.390	0.946
25	-0.832	0.486	0.398	0.123	0.299	0.679	0.553	-0.080	0.030	0.188	0.461	0.258	-0.523	-0.478	0.942
26	-0.103	0.725	0.592	0.400	0.574	0.382	0.865	-0.212	0.510	-0.057	0.785	0.712	-0.244	-0.125	0.942
27	0.260	0.749	0.480	0.605	0.849	0.478	0.583	-0.183	0.417	-0.261	0.845	0.567	0.027	0.088	0.961
28	-0.001	0.610	0.438	0.334	0.503	-0.186	0.202	-0.487	0.497	0.546	0.536	0.335	0.140	0.217	0.958
29	0.174	0.394	0.309	0.088	0.194	-0.164	-0.175	-0.335	0.263	-0.041	0.397	0.001	0.093	0.151	0.963
30	0.061	0.494	0.314	0.280	0.380	-0.215	0.222	-0.570	0.415	-0.151	0.536	0.540	0.569	0.642	1.000
31	-0.292	0.707	0.558	0.400	0.687	0.465	0.667	0.273	0.557	0.049	0.725	0.605	0.191	0.238	0.980
32	0.413	1.000	1.000	0.345	0.779	0.328	0.686	-0.036	0.769	0.228	0.615	0.847	0.328	0.318	0.978
33	-0.071	0.686	0.604	0.284	0.529	0.252	0.738	-0.445	0.403	-0.356	0.664	0.668	0.337	0.288	0.977
34	-0.414	0.557	0.501	0.094	0.298	0.342	0.721	-0.115	0.087	-0.137	0.434	0.195	-0.325	-0.458	-0.108
35	-0.534	0.338	0.198	0.071	0.187	0.338	0.230	0.114	-0.203	0.581	0.375	0.296	-0.280	-0.413	-0.116
36	-0.238	0.246	0.267	-0.200	0.070	-0.088	-0.054	-0.463	0.164	-0.418	0.480	0.290	-0.345	-0.414	-0.106
37	-0.174	0.871	0.572	0.733	1.000	0.265	0.326	-0.075	0.788	-0.587	0.885	0.263	-0.389	-0.424	-0.198
38	-0.508	0.668	0.628	0.220	0.497	0.399	0.360	0.036	0.405	0.519	0.338	0.323	-0.402	-0.399	-0.984
39	-0.786	0.827	0.715	0.388	0.810	0.683	0.872	0.237	0.368	0.345	0.395	0.614	-0.392	-0.379	-0.980
40	0.414	0.956	0.927	0.427	0.716	0.684	0.763	0.022	1.000	0.437	0.580	0.792	-0.380	-0.402	-0.998
41	-0.313	0.974	0.862	0.568	0.861	0.919	0.807	-0.389	0.947	0.184	0.636	0.910	-0.366	-0.400	-0.982
42	0.251	0.822	0.574	0.628	0.848	0.300	0.335	-0.196	0.848	-0.222	0.621	1.000	-0.877	-0.976	-0.998
43	-0.519	0.862	0.688	0.527	0.805	0.658	0.865	-0.129	0.416	-0.075	0.493	0.404	-0.902	-0.965	-1.000

Capítulo B. Características extraídas de las señales de la unidad de quemadores

44	-0.343	0.938	0.917	0.373	0.752	1.000	0.963	1.000	0.773	0.876	0.540	0.650	-0.893	-0.914	-0.997
45	-0.189	0.652	0.536	0.284	0.586	0.602	0.512	-0.024	0.343	-0.292	0.529	0.379	-0.901	-0.911	-0.996
46	-0.136	0.678	0.537	0.329	0.630	0.228	0.474	0.181	0.474	0.609	0.423	0.686	-0.131	-0.082	-0.962
47	-0.240	0.955	0.751	0.701	0.987	0.284	0.760	-0.416	0.840	-0.113	0.704	0.871	0.018	0.017	-0.958
48	0.011	0.849	0.639	0.580	0.848	0.353	0.538	-0.035	0.535	-0.173	0.705	0.712	-0.002	0.033	-0.960
49	-0.425	0.516	0.476	0.090	0.363	0.800	0.839	-0.439	0.281	-0.561	0.656	0.292	-0.107	0.055	-0.970
50	-0.846	0.550	0.465	0.145	0.343	-0.041	0.428	-0.297	0.309	-0.041	0.541	0.046	0.580	0.661	-0.914
51	-1.000	0.934	0.832	0.523	0.853	0.974	1.000	0.196	0.358	-0.271	0.739	0.866	0.133	0.327	-0.928
52	-0.013	0.759	0.649	0.355	0.594	0.373	0.573	0.034	0.584	0.391	0.449	0.066	0.329	0.382	-0.905
53	-0.033	0.740	0.633	0.302	0.623	0.242	0.328	-0.323	0.653	-0.052	0.716	0.940	0.730	0.787	-0.901
54	-0.101	-0.815	-0.801	-0.874	-0.812	-0.444	-0.821	-0.633	-0.784	-0.161	-0.336	-0.755	-0.497	-0.513	0.194
55	0.087	-0.524	-0.643	-0.481	-0.392	-0.469	-0.785	-0.249	-0.452	0.691	-0.392	-0.732	-0.295	-0.286	0.221
56	-0.038	-0.764	-0.759	-0.837	-0.782	-0.723	-0.913	-0.790	-0.707	-0.665	-0.414	-0.819	-0.373	-0.307	0.222
57	0.036	-0.469	-0.526	-0.585	-0.509	0.122	-0.498	0.432	-0.389	0.463	-0.161	-0.695	-0.298	-0.237	0.243
58	0.083	-0.559	-0.729	-0.453	-0.566	-0.358	-0.608	0.027	-0.569	0.474	-0.420	-0.735	-0.521	-0.457	0.234
59	-0.096	-0.887	-0.894	-0.913	-0.864	-0.539	-0.757	-0.278	-0.860	-0.207	-0.410	-0.792	1.000	1.000	0.315
60	0.078	-0.737	-0.737	-0.819	-0.726	-0.640	-0.804	-0.873	-0.538	-0.825	-0.261	-0.686	0.360	0.365	0.287
61	0.144	-0.507	-0.616	-0.489	-0.422	-0.554	-0.640	-0.754	-0.407	-0.478	-0.005	-0.523	0.225	0.265	0.292
62	0.058	-0.676	-0.764	-0.654	-0.636	-0.745	-0.984	-0.627	-0.605	-0.585	0.069	-0.643	0.555	0.574	0.314
63	0.275	-0.447	-0.619	-0.425	-0.519	-0.401	-0.888	-0.186	-0.399	-0.083	0.261	-0.608	0.209	0.236	0.321
64	0.431	-0.398	-0.452	-0.548	-0.412	-0.215	-0.450	-0.221	-0.211	-0.275	0.000	-0.495	-0.122	-0.108	0.313
65	0.396	-0.463	-0.579	-0.504	-0.486	-0.606	-0.894	-0.501	-0.431	0.451	-0.018	-0.412	-0.213	-0.153	0.300
66	0.392	-0.319	-0.422	-0.354	-0.413	-0.559	-0.623	-0.217	-0.042	0.166	0.046	-0.644	-0.123	-0.002	0.309
67	0.059	-0.612	-0.695	-0.607	-0.629	-0.667	-0.869	-0.194	-0.540	0.625	-0.443	-0.776	-0.908	-0.958	0.277
68	0.456	-0.179	-0.387	-0.115	-0.104	-0.472	-0.812	-0.449	-0.061	0.782	-0.022	-0.501	-0.864	-0.957	0.272
69	0.162	-0.383	-0.562	-0.312	-0.329	-0.115	-0.740	0.325	-0.315	0.518	-0.220	-0.441	-0.891	-1.000	0.286
70	-0.011	-0.631	-0.789	-0.534	-0.627	-0.387	-0.748	-0.010	-0.570	-0.051	0.838	-0.633	-0.889	-0.939	0.436
71	0.168	-0.466	-0.623	-0.363	-0.389	0.181	-0.480	0.196	-0.456	0.932	-0.271	-0.602	-1.000	-0.986	0.917
72	0.246	-0.337	-0.267	-0.611	-0.458	-0.542	-0.809	-0.496	-0.125	0.301	-0.086	-0.533	-0.924	-0.915	0.906
73	-0.012	-0.777	-0.804	-0.767	-0.746	-0.943	-0.960	-0.911	-0.707	0.390	-0.564	-0.821	-0.864	-0.881	0.912
74	0.217	-0.582	-0.609	-0.672	-0.615	-0.228	-0.658	-0.278	-0.428	-0.277	-0.400	-0.766	-0.915	-0.934	0.918
75	-0.180	-0.925	-0.993	-0.852	-0.947	-0.693	-1.000	-0.591	-1.000	0.078	-1.000	-1.000	-0.530	-0.416	0.933
76	-0.060	-0.605	-0.741	-0.551	-0.723	-0.418	-0.748	-0.482	-0.573	0.164	-0.516	-0.786	-0.555	-0.483	0.928
77	0.200	-0.618	-0.662	-0.686	-0.691	-0.782	-0.853	-0.393	-0.521	0.349	-0.411	-0.767	-0.490	-0.390	0.946
78	0.003	-0.549	-0.592	-0.625	-0.517	-0.720	-0.793	-0.431	-0.525	0.134	-0.242	-0.714	-0.523	-0.478	0.942
79	0.153	-0.527	-0.578	-0.599	-0.537	-0.617	-0.641	-0.286	-0.520	0.426	-0.382	-0.732	-0.244	-0.125	0.942
80	0.010	-0.811	-0.869	-0.820	-0.879	-0.586	-0.922	-0.497	-0.767	0.104	-0.349	-0.816	0.027	0.088	0.961
81	-0.013	-0.714	-0.734	-0.767	-0.647	-0.514	-0.708	-0.789	-0.784	-0.073	-0.320	-0.706	0.140	0.217	0.958
82	0.192	-0.594	-0.650	-0.634	-0.606	-0.360	-0.822	0.124	-0.530	0.369	-0.428	-0.785	0.093	0.151	0.963
83	0.048	-0.448	-0.490	-0.564	-0.542	0.008	-0.510	0.101	-0.235	-0.248	-0.152	-0.657	0.569	0.642	1.000
84	-0.022	-0.825	-0.829	-0.875	-0.809	-0.640	-0.831	-0.290	-0.770	0.106	-0.622	-0.849	0.191	0.238	0.980
85	0.082	-0.573	-0.597	-0.681	-0.613	-0.151	-0.766	0.186	-0.501	0.896	-0.461	-0.615	0.328	0.318	0.978
86	-0.028	-0.361	-0.471	-0.430	-0.361	0.223	-0.626	0.068	-0.332	0.777	-0.112	-0.467	0.337	0.288	0.977
87	0.162	-0.482	-0.715	-0.315	-0.398	-0.507	-0.929	-0.703	-0.434	0.654	-0.273	-0.683	-0.325	-0.458	-0.108
88	0.059	-0.561	-0.699	-0.504	-0.558	-0.518	-0.718	-0.149	-0.527	-0.040	-0.405	-0.675	-0.280	-0.413	-0.116
89	0.194	-0.349	-0.591	-0.240	-0.278	-0.283	-0.573	0.099	-0.290	-0.277	0.220	-0.437	-0.345	-0.414	-0.106
90	0.260	-0.570	-0.600	-0.672	-0.621	-0.497	-0.791	-0.194	-0.456	-0.261	-0.219	-0.672	-0.389	-0.424	-0.198
91	0.446	-0.387	-0.511	-0.441	-0.417	-0.391	-0.676	-0.702	-0.335	0.364	-0.127	-0.591	-0.402	-0.399	-0.984
92	0.002	-0.782	-0.825	-0.774	-0.808	-1.000	-0.913	-0.698	-0.687	0.156	-0.483	-0.840	-0.392	-0.379	-0.980
93	0.163	-0.396	-0.607	-0.284	-0.370	-0.520	-0.647	-0.589	-0.263	0.125	-0.058	-0.432	-0.380	-0.402	-0.998
94	0.193	-0.513	-0.674	-0.409	-0.472	-0.215	-0.753	-0.394	-0.433	-0.068	-0.395	-0.585	-0.366	-0.400	-0.982
95	-0.196	0.167	-0.327	0.596	0.401	-0.250	-0.862	0.257	0.152	0.762	-0.181	-0.737	-0.877	-0.976	-0.998
96	0.047	-0.710	-0.690	-0.825	-0.702	-0.538	-0.937	-0.618	-0.629	0.391	-0.305	-0.683	-0.902	-0.965	-1.000
97	0.107	-0.381	-0.550	-0.379	-0.422	-0.726	-0.508	-0.384	-0.258	-0.975	0.305	-0.462	-0.893	-0.914	-0.997
98	-0.016	-0.491	-0.532	-0.606	-0.500	-0.215	-0.461	0.009	-0.516	-0.171	0.145	-0.462	-0.901	-0.911	-0.996
99	0.073	-0.555	-0.707	-0.462	-0.566	-0.795	-0.935	-0.556	-0.466	0.594	-0.198	-0.601	-0.131	-0.082	-0.962
100	-0.053	-0.713	-0.801	-0.630	-0.626	-0.832	-0.699	-1.000	-0.661	-1.000	-0.189	-0.648	0.018	0.017	-0.958
101	0.300	-0.714	-0.840	-0.620	-0.667	-0.954	-0.973	-0.585	-0.601	-0.112	-0.314	-0.668	-0.002	0.033	-0.960
102	0.472	-0.556	-0.599	-0.606	-0.605	0.058	-0.654	0.033	-0.249	0.174	-0.386	-0.730	-0.107	0.055	-0.970
103	0.170	-0.576	-0.624	-0.650	-0.572	-0.115	-0.614	0.095	-0.471	0.791	-0.508	-0.773	0.580	0.661	-0.914
104	-0.030	-0.621	-0.688	-0.649	-0.638	-0.493	-0.826	-0.231	-0.598	-0.500	-0.199	-0.650	0.133	0.327	-0.928
105	0.050	-0.087	-0.399	0.046	-0.155	-0.279	-0.669	-0.055	-0.200	0.579	-0.103	-0.271	0.329	0.382	-0.905
106	-0.005	-0.631	-0.682	-0.659	-0.631	-0.434	-0.684	-0.360	-0.564	-0.063	-0.289	-0.761	0.730	0.787	-0.901
107	0.279	-0.515	-0.735	-0.335	-0.414	0.668	0.418	-0.088	0.381	-0.370	0.256	-0.681	-0.497	-0.513	0.194
108	0.576	-0.200	-0.387	-0.182	-0.243	0.538	0.444	-0.305	0.099	-0.280	0.823	-0.087	-0.295	-0.286	0.221
109	0.092	-0.759	-0.830	-0.760	-0.758	0.218	0.241	-0.365	0.204	-0.082	-0.602	-0.847	-0.373	-0.307	0.222
110	0.404	-0.054	-0.341	0.087	0.053	0.327	0.306	-0.132	0.653	0.475	0.133	-0.492	-0.298	-0.237	0.243
111	0.052	-0.513	-0.501	-0.689	-0.542	0.056	0.013	-0.615	0.003	0.375	-0.380	-0.687	-0.521	-0.457	0.234
112	0.560	-0.342	-0.507	-0.295	-0.273	0.387	0.644	0.103	0.656	-0.397	0.285	-0.247	1.000	1.000	0.315
113	0.424	-0.282	-0.444	-0.246	-0.218	0.445	0.372	0.633	0.173	-0.111	0.150	-0.318	0.360	0.365	0.287
114	0.287	-0.412	-0.577	-0.384	-0.496	0.185	0.529	-0.410	0.992	0.016	0.019	-0.699	0.225	0.265	0.292
115	0.251	0.006	-0.337	0.153	-0.038	-0.102	0.463	-0.247	0.567	-0.526	0.410	-0.304	0.555	0.574	0.314
116	0.091	-0.498	-0.602	-0.492	-0.402	-0.055	0.288	-0.185	-0.206	0.852	-0.458	-0.820	0.209	0.236	0.321
117	0.095	-0.386	-0.480	-0.395	-0.311	0.275	0.301	-0.392	0.642	0.450	-0.097	-0.627	-0.122	-0.108	0.313
118	0.115	-0.597	-0.726	-0.542	-0.521	0.406	0.303	-0.829	0.554	-0.142	-0.173	-0.561	-0.213	-0.153	0.300
119	-0.073	-0.742	-0.746	-0.803	-0.735	0.074	0.117	-0.245	0.374	-0.475	-0.375	-0			

Capítulo B. Características extraídas de las señales de la unidad de quemadores

123	0.272	-0.533	-0.693	-0.460	-0.554	0.265	0.512	-0.239	0.296	0.256	0.034	-0.557	-0.889	-0.939	0.436
124	0.007	-0.814	-0.803	-0.875	-0.822	0.190	0.591	-0.259	0.242	-0.427	-0.490	-0.847	-1.000	-0.986	0.917
125	-0.093	0.492	-0.089	1.000	0.817	0.265	0.506	-0.156	0.631	-0.309	0.860	0.445	-0.924	-0.915	0.906
126	0.364	0.010	-0.403	0.372	0.201	0.643	0.517	-0.061	0.559	1.000	-0.088	-0.625	-0.864	-0.881	0.912
127	0.242	-0.308	-0.570	-0.169	-0.217	0.409	0.387	-0.333	0.664	0.080	0.176	-0.336	-0.915	-0.934	0.918
128	0.132	0.337	-0.202	0.764	0.547	0.051	0.331	0.049	0.449	0.687	0.587	0.254	-0.530	-0.416	0.933
129	0.620	-0.187	-0.457	-0.014	-0.191	0.416	0.395	-0.046	0.715	-0.211	0.017	-0.463	-0.555	-0.483	0.928
130	0.266	-0.436	-0.608	-0.358	-0.447	0.083	0.657	-0.696	0.602	0.018	-0.161	-0.622	-0.490	-0.390	0.946
131	0.303	-0.286	-0.574	-0.101	-0.185	0.679	0.553	-0.080	0.030	0.408	-0.119	-0.657	-0.523	-0.478	0.942
132	0.301	-0.246	-0.445	-0.229	-0.261	0.382	0.865	-0.212	0.510	-0.468	0.159	-0.487	-0.244	-0.125	0.942
133	0.184	-0.233	-0.602	0.076	-0.149	0.478	0.583	-0.183	0.417	-0.120	0.268	-0.348	0.027	0.088	0.961
134	0.334	-0.273	-0.566	-0.078	-0.233	-0.186	0.202	-0.487	0.497	0.826	-0.070	-0.436	0.140	0.217	0.958
135	0.383	-0.093	-0.463	0.193	-0.067	-0.164	-0.175	-0.335	0.263	-0.184	0.489	-0.244	0.093	0.151	0.963
136	0.076	-0.521	-0.622	-0.551	-0.624	-0.215	0.222	-0.570	0.415	-0.125	-0.361	-0.803	0.569	0.642	1.000
137	1.000	-0.047	-0.260	-0.013	0.112	0.465	0.667	0.273	0.557	0.374	-0.124	-0.488	0.191	0.238	0.980
138	0.531	-0.393	-0.582	-0.303	-0.320	0.328	0.686	-0.036	0.769	-0.193	-0.268	-0.811	0.328	0.318	0.978
139	0.274	-0.179	-0.514	0.029	-0.102	0.252	0.738	-0.445	0.403	-0.248	0.049	-0.561	0.337	0.288	0.977
140	0.495	-0.066	-0.399	0.114	-0.095	0.342	0.721	-0.115	0.087	0.055	0.428	-0.453	-0.325	-0.458	-0.108
141	0.163	-0.520	-0.626	-0.550	-0.500	0.338	0.230	0.114	-0.203	0.349	-0.345	-0.800	-0.280	-0.413	-0.116
142	0.134	-0.487	-0.658	-0.417	-0.565	-0.088	-0.054	-0.463	0.164	-0.251	0.046	-0.608	-0.345	-0.414	-0.106
143	0.239	-0.433	-0.685	-0.242	-0.388	0.265	0.326	-0.075	0.788	-0.514	0.263	-0.531	-0.389	-0.424	-0.198
144	0.480	0.106	-0.346	0.453	0.262	0.399	0.360	0.036	0.405	-0.247	0.234	-0.438	-0.402	-0.399	-0.984
145	0.600	-0.207	-0.482	-0.049	-0.002	0.683	0.872	0.237	0.368	0.257	0.321	-0.056	-0.392	-0.379	-0.980
146	0.235	-0.268	-0.615	0.015	-0.187	0.684	0.763	0.022	1.000	-0.092	0.269	-0.346	-0.380	-0.402	-0.998
147	-0.118	-1.000	-1.000	-1.000	-1.000	0.919	0.807	-0.389	0.947	-0.344	-0.803	-0.866	-0.366	-0.400	-0.982
148	0.343	-0.438	-0.605	-0.377	-0.346	0.300	0.335	-0.196	0.848	0.308	0.021	-0.471	-0.877	-0.976	-0.998
149	0.417	0.093	-0.315	0.385	0.300	0.658	0.865	-0.129	0.416	-0.258	0.404	-0.486	-0.902	-0.965	-1.000
150	0.256	-0.415	-0.577	-0.400	-0.390	1.000	0.963	1.000	0.773	-0.309	0.029	-0.332	-0.893	-0.914	-0.997
151	0.159	-0.749	-0.822	-0.704	-0.697	0.602	0.512	-0.024	0.343	-0.550	-0.308	-0.756	-0.901	-0.911	-0.996
152	0.901	0.339	-0.065	0.559	0.339	0.228	0.474	0.181	0.474	0.173	0.401	0.041	-0.131	-0.082	-0.962
153	-0.333	-0.076	-0.402	0.118	0.109	0.284	0.760	-0.416	0.840	-0.092	0.321	-0.561	0.018	0.017	-0.958
154	0.533	-0.411	-0.605	-0.293	-0.334	0.353	0.538	-0.035	0.535	-0.239	-0.003	-0.714	-0.002	0.033	-0.960
155	0.233	0.040	-0.389	0.334	0.150	0.800	0.839	-0.439	0.281	-0.430	0.413	0.022	-0.107	0.055	-0.970
156	0.188	-0.488	-0.753	-0.240	-0.260	-0.041	0.428	-0.297	0.309	-0.286	-0.199	-0.739	0.580	0.661	-0.914
157	-0.063	-0.508	-0.639	-0.523	-0.578	0.974	1.000	0.196	0.358	-0.418	0.120	-0.467	0.133	0.327	-0.928
158	0.087	-0.569	-0.660	-0.583	-0.552	0.373	0.573	0.034	0.584	-0.298	-0.271	-0.723	0.329	0.382	-0.905
159	-0.003	-0.581	-0.684	-0.576	-0.644	0.242	0.328	-0.323	0.653	-0.272	0.083	-0.600	0.730	0.787	-0.901

Apéndice C

Tipos de flamas

Tabla C.1: Tipos de flama según tipo de mezcla y tipo de flujo [54]

Tipo de mezcla	Tipo de movimiento	Ejemplos
Premezcla	Turbulento	Motores con encendido por chispa Turbinas de gas estacionarias de bajos NO_x
	Laminar	Llamas planas Llamas Bunsen (seguidas de una vela de difusión para $\Phi > 1$)
De difusión	Turbulento	Motores Diesel Turbinas de aviones Combustión de carbón pulverizado Motores de H_2/O_2
	Laminar	Combustión de madera Quemadores para calefacción Velas




Figura C.1: Estructura de una llama laminar.

Apéndice D

Publicación

Gómez, J. C., Hernández, F., Coello, C. A. C., Ronquillo, G., & Trejo, A. (2013). Flame Classification through the Use of an Artificial Neural Network Trained with a Genetic Algorithm. In *Advances in Soft Computing and Its Applications* (pp. 172-184). Springer Berlin Heidelberg.

Presentado en: Mexican International Conference On Artificial Intelligence (MICAI 2013) del 24 al 30 de noviembre del 2013, Ciudad de México, México.



Bibliografía

- [1] Ballester, J. and García-Armingol, T. (2010). Diagnostic techniques for the monitoring and control of practical flames. *Progress in Energy and Combustion Science*, 36(4):375–411.
- [2] Baukal, C. E. (2001). *The John Zink Combustion Handbook*. Industrial Combustion. Taylor & Francis.
- [3] Bertuccio, L., Fichera, A., Nunnari, G., and Pagano, A. (2000). A cellular neural networks approach to flame image analysis for combustion monitoring. In *Cellular Neural Networks and Their Applications, 2000.(CNNA 2000). Proceedings of the 2000 6th IEEE International Workshop on*, pages 455–459. IEEE.
- [4] Bremermann, H. J. (1962). Optimization through evolution and recombination. *Self-organizing systems*, pages 93–106.
- [5] Cebrian, D. R. (2007). *Desarrollo y simplificación de Redes de Neuronas Artificiales mediante el uso de técnicas de computación evolutiva*. PhD thesis, Universidade da Coruña.
- [6] Chimenti, M., Di Natali, C., Mariotti, G., Paganini, E., Pieri, G., and Salvetti, O. (2004). An ir image processing approach for characterising combustion instability. *Infrared physics and technology*, 46(1):41–47.
- [7] Comision Federal de Electricidad (CFE) (2012). Programa de Obras e Inversiones del Sector Electrico (POISE). Technical report, Comision Federal de Electricidad (CFE).
- [8] Correia, D., Ferrao, P., and Caldeira-Pires, A. (2000). Flame three-dimensional tomography sensor for in-furnace diagnostics. *Proceedings of the Combustion Institute*, 28(1):431–438.
- [9] Crespo, J. P., Sánchez, R. H., Hurtado, P. E., and Baz, D. A. Análisis del eeg mediante la entropía wavelet para la ayuda en el diagnóstico de la enfermedad de alzheimer.
- [10] Deguchi, Y., Noda, M., Abe, M., and Abe, M. (2002). Improvement of combustion control through real-time measurement of O_2 and CO concentrations in incinerators using diode laser absorption spectroscopy. *Proceedings of the Combustion Institute*, 29(1):147 – 153.

-
- [11] Dunteman, G. H. (1989). *Principal Components Analysis*. Number n.º 69 in A Sage Publications. SAGE Publications.
- [12] Energy Information Administration *EIA*, U. (2013). International Energy Outlook 2013. Technical report, U.S. Department of Energy.
- [13] Fine, T. L. (1999). *Feedforward neural network methodology*. Springer.
- [14] Fraser, A. S. (1960). Simulation of genetic systems by automatic digital computers vi. epistasis. *Australian Journal of Biological Sciences*, 13(2):150–162.
- [15] Frish, M., @bookVondrasek2006, title="Tunable Diode Laser Sensor for Monitoring and Control of Harsh Combustion Environments", author="VonDrasek, W. and Melsio-Pubill, A.", year="2006", publisher="United States. Department of Energy. Office of Energy Efficiency and Renewable Energy", Wainner, R., Green, B., Stafford-Evans, J., Laderer, M., and Allen, M. (2004). Progress in reducing size and cost of trace gas analyzers based on tunable diode laser absorption spectroscopy. In *Optics East*, pages 76–82. 2.
- [16] Frish, M., Laderer, M., Wainner, R., Wright, A., Patel, A., Stafford-Evans, J., Morency, J., Allen, M., and Green, B. (2007). The next generation of tdlas analyzers. In *Optics East 2007*, pages 676506–676506. International Society for Optics and Photonics.
- [17] Fuller, T. A., Flynn, T. J., Bailey, R. T., Daw, C. S., Finney, C., Kersting, K., Fields, R., Bermke, R., and Stallings, J. (2003). Field experience with the flame doctor system. In *Proceedings of the Combined Power Plant Air Pollutant Control Mega Symposium, May*, pages 44203–0351.
- [18] Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Artificial Intelligence. Addison-Wesley.
- [19] Goldberg, D. E. (2002). *The Design of Innovation: Lessons from and for Competent Genetic Algorithms* by David E. Goldberg, volume 7. Springer.
- [20] Goldberg, D. E., Deb, K., and Clark, J. H. (1991). Genetic algorithms, noise, and the sizing of populations. *Complex systems*, 6:333–362.
- [21] Hanson, R. K. and Jeffries, J. B. (2006). Diode laser sensors for ground testing. In *25th AIAA Aerodynamic Measurement Technology and Ground Testing Conference*, volume 2, pages 871–882.
- [22] Hao, Z., Qian, X., Cen, K., and Jianren, F. (2004). Optimizing pulverized coal combustion performance based on ann and ga. *Fuel Processing Technology*, 85(2):113–124.
- [23] Hardalupas, Y., Orain, M., Panoutsos, C. S., Taylor, A., Olofsson, J., Seyfried, H., Richter, M., Hult, J., Aldén, M., Hermann, F., and Klingmann, J. (2004). Chemiluminescence sensor for local equivalence ratio of reacting mixtures of fuel and air (FLAMESEEK). *Applied Thermal Engineering*, 24(11–12):1619 – 1632.
- [24] Holland, J. H. (1975). *Adaptation in natural and artificial systems: An introductory analysis with applications to biology, control, and artificial intelligence*. U Michigan Press.
-

-
- [25] Islam, M., Sattar, A., Amin, F., Yao, X., and Murase, K. (2009). A new adaptive merging and growing algorithm for designing artificial neural networks. *Systems, Man, and Cybernetics, Part B: Cybernetics, IEEE Transactions on*, 39(3):705–722.
- [26] Jarosinski, J. and Veyssiere, B. (2009). *Combustion Phenomena: Selected Mechanisms of Flame Formation, Propagation and Extinction*. Taylor & Francis.
- [27] Kesgin, U. (2004). Genetic algorithm and artificial neural network for engine optimisation of efficiency and nox emission. *Fuel*, 83(7):885–895.
- [28] Kohonen, T. (1988). Self-organization and associative memory. *Self-Organization and Associative Memory, 100 figs. XV, 312 pages.. Springer-Verlag Berlin Heidelberg New York. Also Springer Series in Information Sciences, volume 8, 1*.
- [29] Kohse-Höinghaus, K., S. Barlow, R., Aldén, M., and Wolfrum, J. (2005). Combustion at the focus: laser diagnostics and control. *Proceedings of the Combustion Institute*, 30(1):89 – 123.
- [30] Koza, J. (1992). *Genetic Programming: On the Programming of Computers by Means of Natural Selection*. A Bradford book. Bradford.
- [31] Lawn, C. (2000). Distributions of instantaneous heat release by the cross-correlation of chemiluminescent emissions. *Combustion and Flame*, 123(1–2):227 – 240.
- [32] Li, X., Sun, D., Lu, G., Krabicka, J., and Yan, Y. (2012). Prediction of nox emissions through flame radical imaging and neural network based soft computing. In *Imaging Systems and Techniques (IST), 2012 IEEE International Conference on*, pages 502–505. IEEE.
- [33] Liu, X. and Bansal, R. (2012). Optimizing combustion process by adaptive tuning technology based on integrated genetic algorithm and computational fluid dynamics. *Energy Conversion and Management*, 56:53–62.
- [34] Lu, G., Gilabert, G., and Yan, Y. (2005). Vision based monitoring and characterisation of combustion flames. In *Journal of Physics: Conference Series*, volume 15, page 194. IOP Publishing.
- [35] Luo, Z. and Zhou, H. (2007). A combustion-monitoring system with 3-D temperature reconstruction based on flame-image processing technique. *Instrumentation and Measurement, IEEE Transactions on*, 56(5):1877–1882.
- [36] Mahajan, A. and Mahajan, R. (2004). Expert system for flame analysis. In *Cybernetics and Intelligent Systems, 2004 IEEE Conference on*, volume 2, pages 1160–1165. IEEE.
- [37] Martínez, M. M. (2005). *Combustión y quemadores*. Novaprodúctica (Barcelona). Marcombo.
- [38] Nori, V. and Seitzman, J. (2008). Evaluation of chemiluminescence as a combustion diagnostic under varying operating conditions. In *46th AIAA aerospace sciences meeting and exhibit, AIAA, Reno*.
-

-
- [39] Nori, V. N. and Seitzman, J. M. (2009). CH^* Chemiluminescence modeling for combustion diagnostics. *Proceedings of the Combustion Institute*, 32(1):895 – 9032.
- [40] Palmer, H. (2012). *Combustion Technology: Some Modern Developments*. Elsevier Science.
- [41] Panoutsos, C., Hardalupas, Y., and Taylor, A. (2009). Numerical evaluation of equivalence ratio measurement using OH^* and CH^* chemiluminescence in premixed and non-premixed methane–air flames. *Combustion and Flame*, 156(2):273 – 291.
- [42] Romero, C., Li, X., Keyvan, S., and Rossow, R. (2005). Spectrometer-based combustion monitoring for flame stoichiometry and temperature control. *Applied Thermal Engineering*, 25(5–6):659 – 676.
- [43] Rosenblatt, F. (1957). The perceptron: A perceiving and recognizing automaton. Technical Report 85-460-1, Cornell Aeronautical Laboratory.
- [44] Rothlauf, F. (2006). *Representations for Genetic and Evolutionary Algorithms*. Springer.
- [45] Sanz, A., Ballester, J., Hernández, R., and Cerecedo, L. (2008). Advanced monitoring of industrial burners based on fluctuating flame signals. *Fuel*, 87(7):1063 – 1075.
- [46] Stewart, J. E. (1970). *Infrared Spectroscopy: Experimental Methods and Techniques*. M. Dekker.
- [47] Sujatha, K., Pappa, D., and Kalaivani, A. (2010). Combustion quality estimation in power station boilers using median threshold clustering algorithms. *Combustion*, 2(7):2623–2631.
- [48] Sujatha, K., Venmathi, M., and Pappa, N. (2012). Flame monitoring in power station boilers using image processing. *Ictact journal on image and video processing*, 2(4):427–434.
- [49] Sun, D., Lu, G., Zhou, H., and Yan, Y. (2011). Flame stability monitoring and characterization through digital imaging and spectral analysis. *Measurement Science and Technology*, 22(11):114007.
- [50] Sun, D., Lu, G., Zhou, H., and Yan, Y. (2013). Condition monitoring of combustion processes through flame imaging and kernel principal component analysis. *Combustion Science and Technology*, (just-accepted).
- [51] Teichert, H., Fernholz, T., and Ebert, V. (2003). Simultaneous in situ measurement of CO , H_2O , and gas temperatures in a full-sized coal-fired power plant by near-infrared diode lasers. *Applied Optics*, 42(12):2043–2051.
- [52] Torres, C. I., Hernandez, F., Trejo, A., and Ronquillo, G. (2012). Support vector machines applied to a combustion process. In *Electronics, Robotics and Automotive Mechanics Conference (CERMA), 2012 IEEE Ninth*, pages 176–181. IEEE.
- [53] VonDraeseck, W. and Melsio-Pubill, A. (2006). *Tunable Diode Laser Sensor for Monitoring and Control of Harsh Combustion Environments*. United States. Department of Energy. Office of Energy Efficiency and Renewable Energy.
-

- [54] Warnatz, J., Maas, U., and Dibble, R. W. (2006). *Combustion: Physical and Chemical Fundamentals, Modeling and Simulation, Experiments, Pollutant Formation*. Springer.
- [55] Xu, L., Yan, Y., Cornwell, S., and Riley, G. (2004). On-line fuel identification using digital signal processing and fuzzy inference techniques. *Instrumentation and Measurement, IEEE Transactions on*, 53(4):1316–1320.
- [56] Yao, X. (1993). A review of evolutionary artificial neural networks. *International journal of intelligent systems*, 8(4):539–567.
- [57] Yao, X. and Islam, M. M. (2008). Evolving artificial neural network ensembles. *Computational Intelligence Magazine, IEEE*, 3(1):31–42.