

**EQUIPO DE MEDICIÓN PARA LA DETECCIÓN Y CLASIFICACIÓN DE  
VOLÁTILES EN EL PROCESO DE FERMENTACIÓN DE LA ALMENDRA DE  
CACAO EN CÚCUTA – NORTE DE SANTANDER**



Desarrollado por:

**ALEXANDER FLÓREZ MARTÍNEZ**

Director. Ph.D. CRISTHIAN MANUEL DURÁN ACEVEDO

Codirector. Msc JENIFFER KATERINE CARRILLO GÓMEZ

Maestría en Controles Industriales

Facultad de Ingenierías y Arquitectura

Universidad de Pamplona

Pamplona, 22 septiembre 2019

## **Dedicatoria**

Primero que todo doy gracias a Dios por las bendiciones recibidas, a mi madre Rosa María Martínez, por ser esa maravillosa persona que siempre esta presente orientando nuestros caminos, por encomendarnos en sus oraciones, por ser ejemplo de vida, hoy doy gracias a Dios por brindar la oportunidad que nos siga acompañando y deseamos le colme de buena salud, te quiero con todo mi ser.

A mi querida y amada esposa Martha Yanneth Bohórquez Gómez, mis hermosas y adoradas hijas, son mi fuente de inspiración, Sara Isabella Flórez Bohórquez y Mayra Alexandra Flórez Bohórquez, su apoyo, consejos, acompañamiento, fue incondicional para lograr esta maravillosa meta, son mi vida, las quiero infinitamente.

Mis hermanas Martha Flórez M, Nelly Flórez M, Miriam Flórez M, porque en cada una de ustedes encontré una voz de ánimo, de empuje, ejemplo de perseverancia, son únicas y de las cuales he aprendido lo mejor de ustedes, gracias por sus consejos, voz de aliento para seguir adelante en el proceso de formación, el apoyo fue incondicional somos una familia unida es una impronta que nos caracteriza.

## **Agradecimientos**

Agradezco a mis directores de tesis Dr Cristhian Manuel Durán Acevedo y Codirectora Msc Jeniffer Katherine Carrillo Gómez, por el apoyo, asesoría, consultorías todo enmarcado en tiempo dedicado para contribuir al desarrollo de la investigación y formación profesional, exalto ante todo la calidad humana.

Igualmente deseo agradecer al extensionista de FEDECACAO Jorge A Duque, por su contribución en el desarrollo de investigación, siendo una persona experta en el área, con excelente valores humanos y encargado de guiar con sus buenas prácticas la selección y proceso para lograr un cacao de calidad.

Finalmente, al licenciado Emiro Villalba, presidente departamental de cacaoteros Norte de Santander, por estrechar esa mano amiga, abrir las puertas y apoyar el ámbito de la investigación científica en el cultivo de cacao. Resalto es una excelente persona con conocimientos invaluable.

## Tabla de contenido

### Introducción

### Planteamiento del problema y justificación

1	MARCO TEORICO Y ESTADO DEL ARTE .....	16
1.1	Sistema de olfato electrónico .....	16
1.2	Nariz electrónica para la evaluación de la calidad del cacao .....	17
1.3	Técnicas de reconocimiento de patrones en sistemas de olfato electrónico 19	
1.4	Sensores de gases .....	20
1.5	Adquisición de datos .....	22
1.6	Preprocesado de datos en sistemas de olfato electrónico .....	23
1.6.1	Extracción de parámetros .....	24
1.6.2	Preprocesamiento de datos .....	25
1.7	Métodos de reconocimiento de patrones e Inteligencia artificial IA.....	27
1.7.1	Análisis de componentes principales (PCA) .....	27
1.7.2	Análisis de clúster AC .....	28
1.7.3	Análisis de función discriminantes DFA .....	28
1.7.4	Redes Neuronales .....	29
1.7.5	Máquinas de soporte vectorial .....	29
1.7.6	Random Forest.....	32
1.8	Proceso de fermentación del grano de cacao .....	32
2	SELECCIÓN Y ADECUACION DE MUESTRAS DE CACAO .....	33
2.1	Selección del material de cacao .....	33
2.2	Adecuación de muestras de cacao en el proceso de fermentación. ....	37
2.2.1	Protocolo de fermentación del cacao .....	37
2.2.2	Protocolo de secado del cacao .....	38
2.2.3	Fermentación material ICS-95 sano. ....	38
2.2.4	Fermentación material ICS-95 infectado con monilia .....	40
3	EQUIPO DE MEDICIÓN PARA LA DETECCIÓN Y CLASIFICACIÓN DE VOLÁTILES .....	42
3.1	Diagrama de bloques del sistema de olfato electrónico CANOSE .....	42

3.1.1	Cámara de concentración de gases .....	43
3.1.2	Sistema de control de temperatura para la cámara de concentración	44
3.1.3	Cámara de medición de volátiles .....	46
3.1.4	Sistema de adquisición de datos .....	48
3.1.5	Tarjeta CAS: Circuito acondicionamiento de señales salida relé .....	48
3.1.6	Tarjeta CAS: Circuito de acondicionamiento de señal Mosfet IRF520	49
3.1.7	Fuente de alimentación externa.....	49
3.1.8	Fuente de alimentación interna.....	50
3.1.9	Válvulas.....	50
3.1.10	Bomba de diafragma .....	51
4	SOFTWARE DE SUPERVISION, CONTROL Y ADQUISICION DE DATOS DEL SISTEMA DE OLFATO ELECTRÓNICO.....	52
4.1	Partes que conforman el aplicativo de software .....	53
4.2	Protocolo de adquisición .....	56
4.3	Librerías aplicativo de software .....	56
4.4	Ajuste de ganancia para el sistema de control Proporcional-Integral- Derivativo PID.....	57
4.4.1	Caracterizacion del sistema.....	58
4.4.2	Sintonización controlador Proporcional-Integral PI. ....	63
4.4.3	Sintonizacion lazo de control PI, por método Ziegler and Nichols .....	64
4.4.4	Constantes de sintonizacion PI.....	65
4.4.5	Sintonización controlador ideal Proporcional-Integral-Derivativo. ....	66
4.4.6	Contantes de sintonización PID .....	68
4.5	Sistema autónomo para la adquisición de datos en tiempo real .....	69
4.6	Selección de muestras para el análisis de volátiles.....	71
4.6.1	Masa de cacao fermentado 72 horas.....	71
4.6.2	Masa de cacao deseado con 144 horas .....	72
4.6.3	Masa de cacao fermentado 144horas con monilia.....	74
4.6.4	Masa de cacao sobrefermentado.....	74
4.7	Concentración de volátiles emitidos durante análisis de muestras de masa de cacao fermentado por 72 horas. ....	76
4.8	Concentración de volátiles emitidos durante análisis de muestras de masa de cacao fermentado por 144 horas. ....	77

4.9	Concentración de volátiles emitidos durante análisis de muestras de masa de cacao fermentado infectado con monilia por 144 horas. ....	78
4.10	Concentración de volátiles emitidos durante análisis de muestras de masa de cacao sobrefermentado. ....	79
4.11	Operación con acceso remoto.....	79
5	PROCESAMIENTO DE DATOS ANALISIS DE RESULTADOS .....	81
5.1	Análisis de componentes principales PCA .....	82
5.1.1	Preprocesado de datos StandarScaler .....	82
5.1.2	Preprocesado de datos Manhattan .....	84
5.2	Análisis de clúster .....	87
5.3	Análisis de función discriminante .....	88
5.4	Red Neuronal perceptrón multicapa MLPC .....	89
5.4.1	Función de activación para la capa oculta. ....	89
5.4.2	El solucionador para la optimización del peso. ....	89
5.5	Máquina de soporte vectorial .....	97

## Lista de figuras

Figura 1. Comparación entre la estructura de los sistemas de olfato biológico y los de olfato electrónico (Durán, 2005) .....	16
Figura 2. Nariz electrónica para la evaluación de la calidad de cacao (Olunloyo, 2011).....	17
Figura 3. Esquema general de un sistema de olfato electrónico con flujo de aire controlado (Valdez & Gutiérrez, 2016) .....	18
Figura 4. Conformación típica de un sistema de olfato electrónico (Quicazán & Zuluaga, 2011).....	19
Figura 5. Montaje en placa de dos sensores de gases SGX Sensortech MiCS-5524 (Fernández-Muñoz et al., 2017) .....	20
Figura 6. Arduino MEGA 2560 (Villanueva, 2014).....	23
Figura 7. Secuencia para el análisis de aromas (Durán, 2005) .....	23
Figura 8. Extracción de parámetros temporales ante una respuesta de un sensor de óxido de estaño (Durán, 2005) .....	24
Figura 9. Distancias Manhattan y Euclidiana. Las líneas roja, azul y amarilla tienen distancia Manhattan 12, la menor posible. La verde tiene distancia Euclídea 8.49 (Pravin, 2018). .....	26
Figura 10. Direcciones son perpendiculares/ortogonales (Amat, 2017).....	28
Figura 11. Ejemplo de una red neuronal totalmente conectada (Ruiz, Basualdo, & Matich, 2001) .....	29
Figura 12. Hiperplanos de separación en un espacio bidimensional de un conjunto de ejemplos separables en dos clases (Morales, 2012) .....	30
Figura 13. Distribución de las clases y su regla de decisión (Morales, 2012) .....	32
Figura 14. Evolución de las familias de compuestos volátiles principales durante la fermentación en cacao fresco (Castañeda & Rodríguez Jacobo, 2016) .....	33
Figura 15. Corte de mazorca de cacao ICS-95 (Fuente autor) .....	34
Figura 16. Surco material ICS 95. Finca el Amparo, vereda restauración, Cúcuta. 34	
Figura 17. Medida altitud de la plantación de cacao, con GPS Garmin. (Fuente autor). .....	35
Figura 18. Mazorcas de cacao clon ICS-95 (Fuente autor). .....	35
Figura 19. Partida de mazorca con mazo (Fuente autor). .....	35
Figura 20. Almendras de cacao .....	36
Figura 21. Placenta del cacao.....	36
Figura 22. Cacao ICS-95 en baba 800g.....	37

Figura 23. Barril de madera para fermentación de masa de cacao. ....	39
Figura 24. Fermentación en barril material ICS-95 .....	39
Figura 25. Fermentado 72 horas ICS-95 .....	39
Figura 26. Fermentado 144 horas ICS-95 .....	39
Figura 27. Cacao enfermo con monilia .....	40
Figura 28. ICS95 20 Mazorcas afectadas-monilia y germinadas. ....	40
Figura 29. Fermentado ICS95 con monilia 144h. ....	41
Figura 30. Sobrefermentado ICS95 288h .....	41
Figura 31. Diagrama de bloques del equipo de medición multisensorial. ....	42
Figura 32. Sistema de olfato electrónico o nariz electrónica CANOSE (Fuente autor) .....	43
Figura 33. Cámara de concentración de gases. ....	44
Figura 34. Celda de Peltier como elemento de generación de calor para calentar las muestras de cacao .....	44
Figura 35. Sensor de temperatura LM35 instalado en cámara de concentración de volátiles. ....	45
Figura 36. Cámara de medición de volátiles. ....	47
Figura 37. Sensores de gas fabricante MQ (Llamas, 2016) .....	47
Figura 38. Diagrama de conexión Arduino MEGA con el sistema CANOSE (Fuente autor). ....	48
Figura 39. Circuito acondicionador de señal, salida relé (Fuente autor). ....	49
Figura 40. Tarjeta MOSFET, activación sistema de temperatura por PWM (Fuente autor). ....	49
Figura 41. Fuente de instrumentación interna (Fuente autor). ....	50
Figura 42. Válvulas solenoides normalmente cerradas (Fuente autor). ....	50
Figura 43. Bomba de diafragma para flujo de aire (Fuente autor). ....	51
Figura 44. Partes que conforma el aplicativo de software para el control automático del sistema de olfato electrónico (Fuente autor). ....	53
Figura 45. Curva de reacción cámara de concentración (Fuente autor) .....	57
Figura 46. Constantes para identificación de los modelos de primer orden más tiempo muerto (Alfaro Ruíz, 2011). ....	58
Figura 47. Gráfico de temperatura vs Voltaje en celdas de Peltier (Carlson, 2018) .....	59
Figura 48. Selección valor %P1(t1) con el 25% del valor de la señal de proceso (Fuente autor) .....	60
Figura 49. Selección valor %P2(t2) con el 75% del valor de la señal de proceso (Fuente autor) .....	61
Figura 50. Función de transferencia en lazo abierto de la cámara de concentración por el método de Alfaro. ....	62
Figura 51. Sistema de control en lazo abierto por método de Alfaro. ....	62
Figura 52. Configuración del tiempo muerto utilizando el software Matlab-librería Simulink. ....	63



Figura 53.Simulación en Matlab de la curva de proceso en lazo abierto por el método de Alfaro.....	63
Figura 54.Sistema de control acción Proporcional-Integral (PI) (Odwyen, 2009)..	64
Figura 55.Diagrama de bloques del sistema de control en lazo cerrado implementando un controlador PI.....	65
Figura 56.Bloque de parámetros en Simulink para el ingreso de constantes PI. ..	65
Figura 57.Respuesta del sistema con controlador PI implementando método de Ziegler and Nichols. ....	66
Figura 58.Respuesta del sistema de control de temperatura PI método Ziegler and Nichols (Fuente autor).....	66
Figura 59.Sistema de control acción Proporcional-Integral-Derivativo (PID)(Odwyen, 2009) .....	67
Figura 60.Diagrama de bloques del sistema de control en lazo cerrado implementando un PID.....	68
Figura 61.Respuesta del sistema con controlador PID implementando el Método CHIEN.....	69
Figura 62.Controlador PID método CHIEN (Fuente autor) .....	69
Figura 63.Vista general nariz electrónica CANOSE (Fuente autor). ....	70
Figura 64.Cámara de concentración de volátiles abierta (Fuente autor).....	70
Figura 65.Cámara de concentración de muestras cerrada (Fuente autor).....	71
Figura 66.Ejecución del software en el proceso de adquisición de datos (Fuente autor). ....	71
Figura 67. Muestras seleccionadas cacao con 72horas de fermentado, clon ICS-95 (Fuente autor). ....	72
Figura 68. Muestras seleccionadas para una fermentación de 144horas clon ICS-95 cacao (Fuente autor). ....	73
Figura 69. Fermentación de 144horas clon ICS-95 cacao enfermo con monilia (Fuente autor). ....	74
Figura 70.Muestras seleccionadas cacao sobrefermentado, clon ICS-95. ....	75
Figura 71.Volátiles adquiridos por la nariz electrónica CANOSE con un tiempo de fermentación de 72horas (Fuente autor). ....	76
Figura 72.Volátiles adquiridos por la nariz electrónica CANOSE con un tiempo de fermentación de 144horas (Fuente autor). ....	77
Figura 73.Volátiles adquiridos por la nariz electrónica CANOSE con un tiempo de fermentación de 144 horas infectado con monilia (Fuente autor). ....	78
Figura 74.Volátiles adquiridos por la nariz electrónica CANOSE aplicado a muestras de cacao sobrefermentado (Fuente autor).....	79
Figura 75.Iniciando el servidor web para supervisión remota (Fuente autor).....	80
Figura 76.Supervisión remota mediante navegador internet Explorer (Fuente autor). ....	80
Figura 77.Diagrama de bloques general para el análisis de volátiles en el proceso de cacao fermentado (Fuente autor). ....	81
Figura 78.Matriz de datos preprocesado StandarScaler (Fuente autor). ....	82

Figura 79.Preprocesado de datos StandarScaler en Python (Fuente autor). .....	83
Figura 80.Distribución de muestras mediante análisis de componentes principales con preprocesado StandarScaler PC1=0.975767 (Fuente autor). .....	83
Figura 81. Clústeres asociados al proceso de fermentación de cacao mediante el uso de análisis de componentes principales preprocesado StandarScaler PC1=0.975767 y PC2=0.0154888 (Fuente autor). .....	84
Figura 82.Matriz de datos preprocesado Manhattan (Fuente autor). .....	85
Figura 83.Preprocesado de datos Manhattan en Python (Fuente autor). .....	85
Figura 84.Distribución de muestras mediante análisis de componentes principales con preprocesado Manhattan PC1=0.898028 (Fuente autor). .....	86
Figura 85.Clústeres asociados al proceso de fermentación de cacao mediante el uso de análisis de componentes principales preprocesado Manhattan PC1=0.898028 y PC2=0.0675872 (Fuente autor). .....	87
Figura 86.Análisis de clúster en el proceso de fermentado de cacao (Fuente autor). .....	88
Figura 87.Análisis de función discriminante aplicado al proceso de fermentado de cacao (Fuente autor). .....	89
Figura 88.Matriz con preprocesado de datos Manhattan para entrenamiento de la red neuronal (Fuente autor). .....	91
Figura 89.Datos de entrenamiento (X_train) (Fuente autor). .....	92
Figura 90.Objetivos seleccionados para el entrenamiento de la red neuronal (y_train) (Fuente autor). .....	92
Figura 91.Matriz de prueba (X_test) (Fuente autor). .....	93
Figura 92.Datos de prueba, objetivos de la red neuronal (y_test) (Fuente autor). .....	93
Figura 93.Predicción de resultados objetivos de la red neuronal MLPC con 3,3,3 capas ocultas en Python (Fuente autor). .....	94
Figura 94.Predicción de resultados objetivos de la red neuronal MLPC con 7,7,7 capas ocultas en Python (Fuente autor). .....	95
Figura 95.Matriz con muestras de cacao nuevas, fermentado 144h (Fuente autor). .....	95
Figura 96.Matriz de procesado del modelo de entrenamiento (Fuente autor). .....	96
Figura 97. Validación red neuronal MPLC (Fuente autor). .....	97
Figura 98.Máquina de soporte vectorial Kernel poly- preprocesado StandardScaler (Fuente autor). .....	97
Figura 99.SVM Kernel rbf radial basis function kernel (Fuente autor). .....	98
Figura 100.SVM Kernel rbf radial basis function kernel (Fuente autor). .....	99
Figura 101.Socialización proyecto.....	100

## Lista de tablas

Tabla 1. Tipos de sensores MQ existentes en el mercado (Millán, 2016).....	21
Tabla 2. Parámetros estáticos extraíbles en los sensores de óxidos metálicos (Brezmes, 2001). .....	24
Tabla 3. Referencias de sensores de gases MQ que hacen parte de la cámara de medida (Llamas, 2016) .....	47
Tabla 4. Descripción de las partes que conforman el aplicativo de software para el control automático de la nariz electrónica CANOSE.....	56
Tabla 5. Contantes de sintonización PI, método Ziegler and Nichols (Odwyen, 2009).....	64
Tabla 6. Contantes de sintonización PID, métodos Ziegler and Nichols, CHIEN (Odwyen, 2009) .....	67
Tabla 7. Promedio peso de muestra de masa de cacao con 72 horas de fermentación. ....	72
Tabla 8. Promedio peso de muestra de masa de cacao con 144 horas de fermentación (Fuente autor).....	73
Tabla 9. Promedio peso de muestra de masa de cacao infectado con monilia 144 horas de fermentación (Fuente autor). ....	74
Tabla 10. Promedio peso de muestra de masa de cacao sobrefermentado (Fuente autor). ....	75
Tabla 11. Predicción red neuronal MLPC con 3,3,3, capas ocultas.....	93
Tabla 12. Predicción red neuronal MLPC con 7,7,7, capas ocultas.....	94

## INTRODUCCION

Para garantizar la producción en la elaboración de un producto en la industria de alimentos, se hace fundamental implementar procesos automatizados que permitan realizar control de calidad del producto y como resultado se pueda determinar si es apto para el consumo humano y su comercialización. En algunos procesos se presenta el control de calidad sensorial como un elemento clave para mantener la confianza del consumidor, los cuales tienen la capacidad de percibir un cambio de color, sabor, aroma en el producto, el cual puede ser aceptado o rechazado.

El desarrollo del presente proyecto centra la investigación en el diseño y construcción de un equipo electrónico multisensorial denominado nariz electrónica, para la detección y clasificación de compuestos volátiles emitidos durante el proceso industrial de fermentación de la almendra de cacao, el equipo lo conforma una matriz de sensores los cuales integran un pequeño calentador en el interior, con un sensor electroquímico que reacciona ante una concentración conocida de gases y cuya señal electrónica de salida es de tipo analógico en voltaje. Se desarrolla e implementa un sistema de medición autónomo para adquisición y procesamiento de datos en PC con ejecución en tiempo real. Para optimizar el sistema de muestreo se diseñó una etapa para el control de temperatura proporcional integral derivativo PID. El equipo electrónico adicionalmente dispone de una cámara, donde será acondicionada la muestra de cacao y mediante un ducto, se hace circular un flujo de aire con motivo de homogeneizar los volátiles que serán detectados por la matriz de sensores. Como resultado se clasifica y agrupan las concentraciones de compuestos volátiles mediante algoritmos basados en técnicas de reconocimiento de patrones y/o machine learning (aprendizaje de máquina), permitiendo predecir la calidad de la almendra de cacao en el proceso de fermentación.

## PLANTEAMIENTO DEL PROBLEMA Y JUSTIFICACIÓN

Colombia es el único país cacaotero del mundo que cuenta con una variedad de agro ecosistemas y que cultiva una amplia gama de clones que permite la posibilidad de seleccionar y lograr mejoras en la productividad y calidad y con ello la posibilidad de obtener diversos perfiles finales de cacao catalogados como finos y de aroma (Pinzón, 2012).

En el año 2010 la organización internacional del cacao (ICCO) reporta que el cacao colombiano fue catalogado como cacao fino y de aroma, generando valor agregado para la comercialización del grano (Ríos, 2017).

La fermentación del cacao es una etapa muy importante en el procesamiento del grano, ya que se producen cambios bioquímicos que dan origen a los precursores del aroma y sabor (Contreras et al., 2002).

Durante el proceso de fermentación, el etanol y el ácido acético se difunden dentro del grano, que, junto con el incremento de la temperatura, matan el embrión de la semilla y la estructura interna del grano se descompone, liberando compuestos y pigmentos que interactúan bioquímicamente con hidrolasas endógenas activadas, para desarrollar precursores del aroma y color (Afoakwa, Paterson, Fowler, & Ryan, 2008).

Se han realizado estudios recientes sobre identificación de compuestos volátiles en el proceso de fermentación del cacao, implementando técnicas de micro extracción en fase solida con modo de espacio de cabeza, head space-solid phase microextraction (HS-SPME) acoplada a cromatografía de gases con detectores de espectrometría de masas (Castañeda & Rodríguez Jacobo, 2016). Debido a que son procedimientos de laboratorio requieren de equipos especiales de alto costo para el análisis a ello se suma la subjetividad humana también está inmersa en el proceso de manufactura del cacao, teniendo en cuenta estas consideraciones, la presente investigación tiene como objetivo, diseñar un sistema de olfato electrónico de bajo costo, que permita realizar la detección y clasificación en la evolución de los principales compuestos volátiles durante el proceso de fermentación.

La implementación del olfato electrónico en la etapa de fermentación permitirá identificar aromas que sean indicadores de calidad del grano de cacao, los beneficios se verán reflejados al momento de clasificar muestras con periodos largos de fermentación y que efectivamente afectan aroma y sabor del producto

final. Otro beneficio alude al factor económico ya que el procesamiento de granos no deseados estaría presente a lo largo de la cadena de producción y finalmente afectan la calidad del producto.

Los resultados obtenidos contribuirán en la Investigación, desarrollo e innovación “I+D+i” de la cadena del cacao en Colombia y se podría pensar en llegar a estandarizar un método para que cada planta en el proceso de manufactura del cacao, llegara a tener un equipo de estas características.

## **OBJETIVOS**

Desarrollar un equipo de medición multisensorial para la detección y clasificación de volátiles en el proceso industrial de fermentado de la almendra de cacao en Cúcuta – Norte de Santander.

## **OBJETIVOS ESPECÍFICOS**

- Acondicionar las muestras de cacao las cuales serán utilizadas para el entrenamiento y validación del equipo de medición.
- Realizar un sistema de medición sensorial acorde a los volátiles emitidos por los almendros del cacao.
- Implementar el sistema autónomo la para adquisición de datos en tiempo real, ajustado al número de volátiles que se detecten en la almendra de cacao fermentado.
- Implementar técnicas de pre-procesamiento y métodos de reconocimiento de patrones e inteligencia artificial para realizar la clasificación de los volátiles.
- Desarrollar un controlador para variables físicas (temperatura y/o humedad).
- Desarrollar una aplicación (app o SCADA) para el control y supervisión del sistema, que permita operar el dispositivo electrónico desde un sitio remoto con el fin de almacenar la data para su posterior análisis de resultados.
- Validar el equipo electrónico sensorial a través de un panel de expertos sensoriales.

# 1 MARCO TEORICO Y ESTADO DEL ARTE

El presente capítulo aborda temáticas enmarcadas en el desarrollo e implementación de sistemas de olfato electrónico uso y aplicaciones, técnicas de pre-procesado y procesamiento, clasificación de datos, algoritmo basados en técnicas de reconocimiento de patrones, aprendizaje de máquina, finalmente se documenta el proceso de manufactura de cacao en la fase de fermentación.

## 1.1 Sistema de olfato electrónico

La figura 1, ilustra comparativo entre la estructura de olfato biológico y el equivalente a un sistema de olfato electrónico.

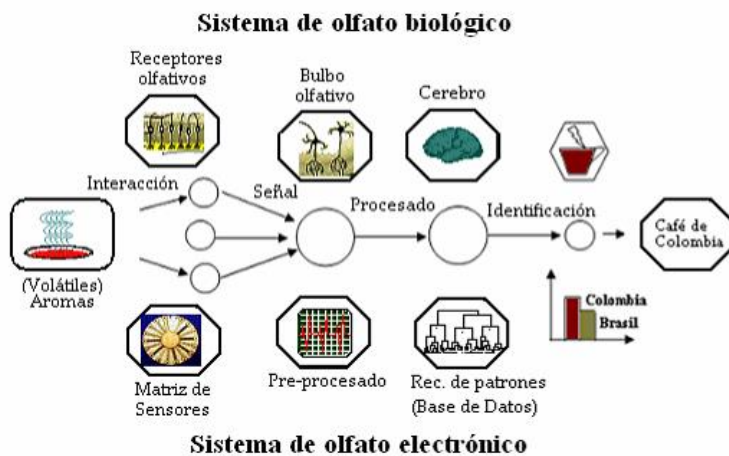


Figura 1. Comparación entre la estructura de los sistemas de olfato biológico y los de olfato electrónico (Durán, 2005)

Como se puede observar los receptores olfativos están representados por un grupo de sensores químicos (matriz de sensores) que producen una señal eléctrica dependiente del tipo de aroma detectado. El bulbo olfativo recibe estas señales para posteriormente enviarlas al cerebro a través de los nervios que, de forma muy similar a las técnicas de pre-procesado, preparan las señales reduciendo el volumen de información y minimizando el ruido y las derivas que introducen los quimiorreceptores. Esta tarea facilita la clasificación o identificación de la muestra por medio de un sistema de reconocimiento de patrones. Los métodos de



reconocimiento de patrones realizan funciones equivalentes a las que se realizan en la corteza del cerebro, que es la etapa final del proceso olfativo humano, donde se identifican, clasifican, interpretan y memorizan los diferentes aromas aprendidos a lo largo del tiempo (Durán, 2005).

## 1.2 Nariz electrónica para la evaluación de la calidad del cacao

Los sistemas de olfato electrónico, más comúnmente conocidos en la industria agroalimentaria como narices electrónicas, son considerados hoy en día como una técnica de análisis de gran aplicabilidad y una práctica no destructiva diseñada para determinar, reconocer e identificar niveles muy bajos de sustancias químicas volátiles. Un arreglo de sensores electroquímicos crea una huella única digital del alimento, haciendo posible el control de calidad, el desarrollo de productos, la caracterización, clasificación y diferenciación por origen y por estado de madurez, la evaluación de su tiempo de vida útil y también como herramienta de control para identificar problemas que amenazan la comercialización, como la falsificación y la adulteración (Quicazán & Zuluaga, 2011).

En el proceso de manufactura para la elaboración del chocolate, se han desarrollado equipos para el análisis de muestras de cacao en la fase de tostado, la figura 2 ilustra el equipo de medición.



DAQ: data acquisition card      SC: signals conditioner      P: vacuum pump  
Sa: sample chamber              Sc: sensor chamber              SV: solenoid valve  
HC: heating chamber.

Figura 2. Nariz electrónica para la evaluación de la calidad de cacao (Olunloyo, 2011)

El elemento de detección utilizado en este trabajo es un sensor de gas Fígaro TGS, que consiste en un semiconductor de óxido de estaño ( $\text{SnO}_2$ ), con baja conductividad en aire limpio. Las muestras a ensayar se precalentaron en una cámara de calentamiento, encerrada en un baño de agua, cuya temperatura se controlaba mediante un sensor integrado con el programa de adquisición. Se instaló un sensor de humedad dentro de la cámara. Nuestro experimento para la

adquisición de huellas de olor de cacao tuvo lugar a temperatura de cámara de muestra de 60 °C y humedad relativa del 70% (Olunloyo, 2011).

Otros sistemas de olfato electrónico, implementan flujo de aire controlado, para analizar el aroma generado en barras de chocolate, es decir en la etapa del producto terminado. La figura 3, ilustra diagrama de bloques integrado por un olfatimetro, arreglo de sensores de gas, sistema de adquisición de datos y equipo de computo.




Figura 3. Esquema general de un sistema de olfato electrónico con flujo de aire controlado (Valdez & Gutiérrez, 2016)

Otros elementos fundamentales que hacen parte del sistema de olfato electrónico corresponden a la etapa de medición caracterización y reconocimiento de patrones ver figura 4:

- a) Una etapa de medición, compuesta por una técnica de extracción de aroma o sistema de flujo de aire, que transporta los compuestos volátiles de las muestras hasta un arreglo de sensores químicos que transforman la información recibida en señales eléctricas;
- b) Una técnica de extracción de los rasgos característicos de la muestra analizada, mediante la cuantificación y transformación en datos de las señales de los diferentes sensores.
- c) Los métodos de reconocimiento de patrones para identificar y clasificar el aroma de las muestras medidas.

El propósito de combinar un arreglo de sensores es proveer una señal global llamada "huella digital" como la respuesta simple de un aroma característico de la muestra

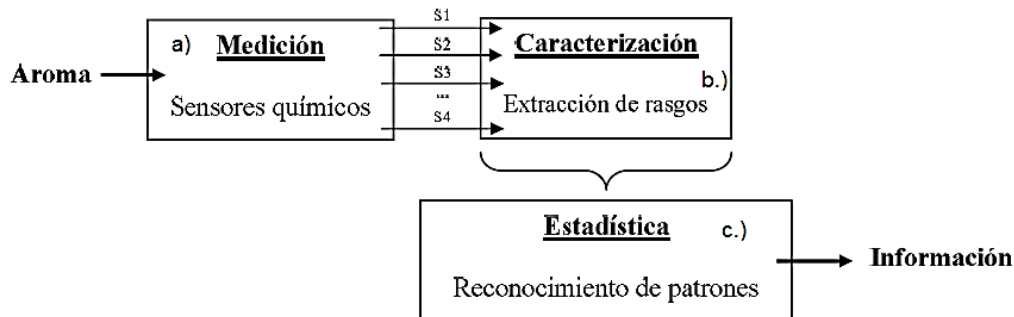


Figura 4. Conformación típica de un sistema de olfato electrónico (Quicazán & Zuluaga, 2011)

Las narices electrónicas fueron desarrolladas en un comienzo para reemplazar a los paneles de expertos en la clasificación de aromas, debido a que estos se consideran costosos, difíciles de transportar, y algunas veces subjetivos, debido a que sus valoraciones se pueden ver afectadas por el cansancio, estado anímico, el clima y otros factores externos. Algunas veces estos paneles de expertos se han apoyado en cromatógrafos de gases y espectrómetros de masas, no sólo clasificando olores sino también cuantificándolos, todo esto con un elevado costo en tiempo y en dinero. En la actualidad las narices electrónicas no son solamente usadas para clasificaciones de aroma, sino también para la detección de olores. De ahí que su importancia y utilización se haya extendido a aplicaciones en la agroindustria, medio ambiente, la seguridad, y la medicina (Moreno, Caballero, Galán, Matía, & Jiménez, 2009)

Otra aplicabilidad de la nariz electrónica se caracteriza por ser un instrumento de medida no invasivo que ofrece la ventaja de realizar un análisis y control sobre el estado actual de los alimentos, sin destruir el producto final. tiene la capacidad analítica que permite, en poco tiempo, detectar, compuestos orgánicos volátiles de alimentos, responsables de su olor y aroma, permitiendo la aplicación de esta tecnología en el control de la calidad alimentaria (Durán & Guadrón, 2014)

### 1.3 Técnicas de reconocimiento de patrones en sistemas de olfato electrónico

Los datos provenientes de la nariz electrónica poseen un alto grado de redundancia debido, por una parte, a la sensibilidad cruzada de los sensores de gas, y también a la elevada dimensionalidad de los datos acondicionados del array de entrada. El preprocesado de datos busca reducir la dimensionalidad, con el fin de obtener un conjunto de valores numéricos (o vector característico) asociado a cada aroma lo más compacto posible, con miras a su posterior clasificación e identificación. Las herramientas matemáticas más habitualmente utilizadas en este bloque son el Análisis de Componentes Principales (PCA, del inglés Principal Component

Analysis) y el Análisis Discriminante Lineal (LDA, del inglés Linear Discriminant Analysis). El algoritmo PCA, de naturaleza no supervisada, define una transformación lineal del sistema de coordenadas de entrada en otro que permite categorizar en cada dimensión las varianzas relativas del conjunto de datos de forma ordenada. Como resultado, se determinan los componentes principales de la distribución como aquellas dimensiones asociadas a varianzas más significativas (Fernández-Muñoz, Herrero-Agustín, Lozano-Rogado, Santos-Blanco, & Suárez-Marcelo, 2017).



Figura 5. Montaje en placa de dos sensores de gases SGX Sensortech MiCS-5524 (Fernández-Muñoz et al., 2017)

#### 1.4 Sensores de gases

Los sensores de gases se caracterizan por ser de tipo electroquímicos, internamente poseen un filamento calefactor encargado de aumentar la temperatura interna del sensor y al detectar diversos tipos de gases, produce un cambio en el valor de la resistencia interna y voltaje de salida.

Existe una gran cantidad de sensores MQ (MQ-2, MQ-3, MQ-4), económicos y capaces de medir una gran cantidad de gases (por ejemplo, Propano, Metano, Butano, LPG, Humo, Alcohol, Etanol, Gas natural, Hidrógeno, Monóxido de carbono, Gases inflamables, Ozono, Benceno, Sulfuro de hidrógeno, Amoníaco, Tolueno, Acetona). Diferentes sensores pueden medir el mismo tipo de gas (por ejemplo, el alcohol lo pueden detectar los sensores MQ-2, MQ-3 y MQ-5) aunque se debe saber que cada uno detecta unos rangos distintos, tanto para este gas como para el resto de gases. Pese al abanico de modelos todos ellos se conectan

y usan de la misma forma, por lo que habrá explicaciones que serán comunes en todos ellos. Son adecuados para detección de fugas de gas en casas, talleres, edificios comerciales, sistema de seguridad para detección contra incendios, monitorización de gases contaminantes, etcétera. Otras características importantes es que tienen alta sensibilidad, respuesta rápida, son capaces de detectar un amplio rango, su funcionamiento es estable, tienen larga vida y el circuito de accionamiento es simple (Villanueva, 2014).

A continuación, en la tabla 1, se puede visualizar el tipo de gas que puede medir cada sensor según la referencia seguido del rango de medición en partes por millón (ppm) del fabricante MQ

Sensor	Gases que puede detectar	Rango de detección (ppm)
MQ-2	Hidrógeno	300-5000
	LPG y Propano	200-5000
	Metano	5000-20000
	Monóxido de carbono	No especificado
	Alcohol	100-2000
MQ-3	Alcohol	25-500
	Benceno, Metano, Hexano, LPG y CO	No especificado
MQ-4	Metano	200-10000
	Hidrógeno, Monóxido de carbono, Alcohol y Humo	No especificado
MQ-5	LPG y Gas natural (butano, propano, gas ciudad)	200-10000
	Hidrógeno, Monóxido de carbono y Alcohol	No especificado
MQ-6	LPG	200-10000
	Hidrógeno, Metano, Monóxido de carbono y Alcohol	No especificado
MQ-7	Monóxido de Carbono	20-2000
	Hidrógeno, LPG, Metano y Alcohol	No especificado
MQ-8	Hidrógeno	100 - 10000
	LPG, Metano, Monóxido de carbono y Alcohol	No especificado
MQ-9	LPG	500-10000
	Monóxido de carbon	20-2000
	Metano	500-10000
MQ-131	NOx y CL2	No especificado
	O <sub>3</sub>	10ppb – 2 ppm
MQ-135	Amoniaco	100-300
	Alcohol	10-300
	Benceno	10-1000
	NOx, Humo y Dióxido de carbono	No especificado
MQ-136	Monóxido de carbono y Amonio	No especificado
	Sulfuro de hidrógeno	1-100
MQ-137	Monóxido de carbon	No especificado
	Amoniaco	5 - 200
MQ-138	Benceno y Alcohol	10 - 1000
	Amoniaco	10 - 3000
	Metano, Monóxido de carbono y Propano	No especificado

Tabla 1. Tipos de sensores MQ existentes en el mercado (Millán, 2016)

Otro tipo de sensor de gases comerciales y empleados en diferentes áreas son los TGS (Taguchis) de la casa japonesa Figaro Inc, concretamente de óxido de estaño.

Este tipo de sensores son muy utilizados en los sistemas de olfato electrónico, ya que presentan una alta sensibilidad ante la presencia de diversos volátiles orgánicos y el tiempo de vida es largo. Los sensores semiconductores basan su funcionamiento en la variación de la resistencia que presenta su capa activa química ante diferentes compuestos volátiles. La sensibilidad de estos sensores se puede definir como la relación entre el incremento de concentración de un determinado gas y el incremento de resistencia que se produce. (Durán & Guadrón, 2014)

## **1.5 Adquisición de datos**

La función principal de un sistema de adquisición de datos es realizar la comunicación entre dispositivos sensores, actuadores con un controlador, generalmente es un equipo de cómputo. Los sistemas basados en microcontrolador Arduino, desarrollan un papel importante debido a la flexibilidad en programación, altas prestaciones en el número de canales de entrada/salida, velocidad de procesador aproximadamente 16MHz con memoria EEPROM: 4KB, otra de las bondades es su bajo costo. Algunas referencias de tarjetas son, Arduino nano, Arduino uno y la más completa debido a los canales de entrada/salida y procesamiento es la Arduino MEGA, a continuación, se describen las características principales

Arduino MEGA 2560. Dispone de 16 canales analógicos preparados únicamente para recibir entradas de señales, así como 54 canales digitales de entrada y salida. Sin embargo, hay que destacar que algunos de estos pines tienen un uso reservado para otros fines, como es el caso de los pines digitales 0 y 1, destinados a la comunicación serie mediante cable USB. Si fuera necesario establecer una comunicación serie con más de un dispositivo, existen otras parejas de pines que pueden cumplir con este fin (los pines 18-19 forman el Serial1, el 16-17 el Serial2, y el 14-15 son el Serial3). Es necesario comentar que existe una librería en Arduino IDE, Software Serial que permite escoger 2 pines digitales cualquiera para realizar esta función (Villanueva, 2014).

Por otro lado, los pines digitales del 2 al 13, pueden ser usados como salidas de PWM, es decir ofrecer como salida un valor de tensión entre 0 y 5 V, mediante una señal que está activa a 5V durante un tiempo para luego volver a 0V, controlando el tiempo de que permanece la señal en estado alto durante un tiempo de ciclo determinado (de 0% a 100%). En cuanto a la manera de alimentar eléctricamente a la placa, el método más sencillo es la conexión a través del cable USB directamente al ordenador (Villanueva, 2014).

La figura 6, enmarca los puertos que integra la tarjeta Arduino Mega 2560.




Figura 6.Arduino MEGA 2560 (Villanueva, 2014)

### 1.6 Preprocesado de datos en sistemas de olfato electrónico

Los sistemas de medición de olfato electrónico, están compuestos por sensores de gases que cambian sus propiedades físicas en función del entorno gaseoso en el que se vea inmersa la capa activa del dispositivo. Estos cambios se traducen en una respuesta eléctrica generando así una señal dependiente de la presencia de las concentraciones de sustancias que se quieren medir. Esta respuesta generada en el dominio eléctrico es acondicionada para ser leída y almacenada en un ordenador. Tras ser adquiridas y almacenadas, las señales son tratadas por métodos de extracción de parámetros y pre-procesado de datos. La técnica de extracción de parámetros es fundamental, especialmente al utilizar sensores de gases. La información que se puede extraer del sensor es muy variada (Durán, 2005).

La figura 7, ilustra la secuencia en cada etapa del análisis de gases, desde el acondicionamiento de las muestras, medición, extracción de rasgos, reconocimiento visualización y clasificación.

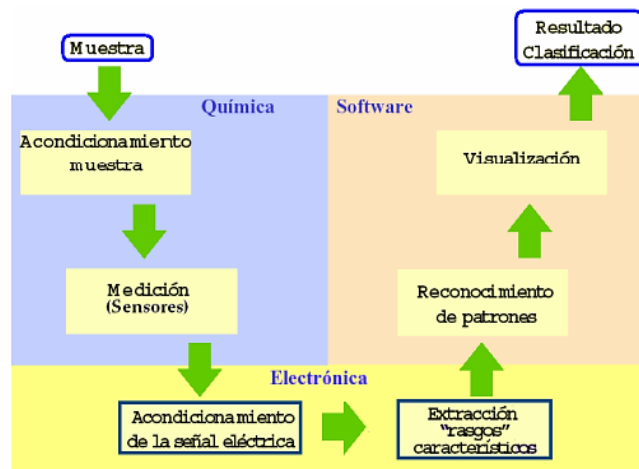


Figura 7.Secuencia para el análisis de aromas (Durán, 2005)

### 1.6.1 Extracción de parámetros

Los sensores de estaño basan su funcionamiento en el cambio de conductividad que experimenta su capa activa ante la presencia de gases reductores. El cambio de conductividad con lleva unos transitorios que llevan a la capa activa del sensor desde una situación de reposo a una conductancia final que depende del tipo de volátil y de su concentración. La información que se puede extraer del comportamiento del sensor es muy variada. si se obtienen los valores de conductancia inicial y/o final se dice que se están utilizando parámetros estáticos. con ello se pueden hacer varias combinaciones que se detallan en la tabla 2.

$G_i$	Conductancia inicial
$G_f$	Conductancia final
$\Delta G$	Incremento de conductancia ( $G_f - G_i$ )
$\Delta_{gn}$	Incremento de conductancia normalizada $\Delta_g / G_i$

Tabla 2. Parámetros estáticos extraíbles en los sensores de óxidos metálicos (Brezmes, 2001).

La figura 8, muestra el transitorio de conductancia típico de un sensor de gas de óxido de estaño frente a un cambio rápido en las concentraciones de amoníaco, donde se puede observar como el transitorio ( $T_r$ ) tarda unos segundos en llegar a un máximo y como del se pueden extraer parámetros estáticos y parámetros dinámicos. Si se obtienen valores de conductancia inicial y/o final se dice que se están usando parámetros estáticos (Durán, 2005)

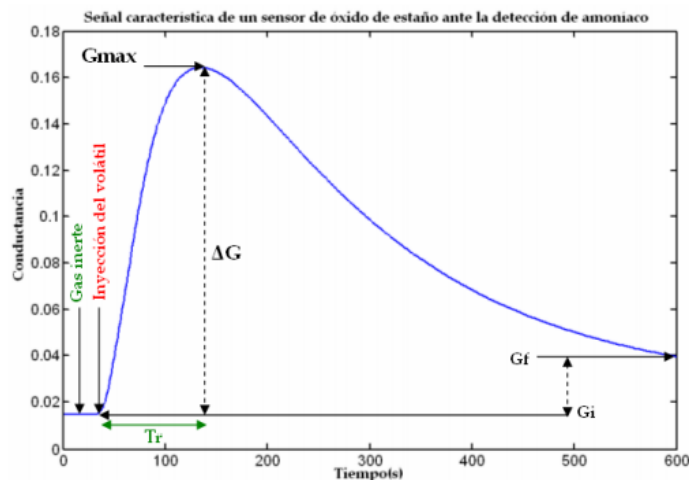


Figura 8.Extracción de parámetros temporales ante una respuesta de un sensor de óxido de estaño (Durán, 2005)



## 1.6.2 Preprocesamiento de datos

Después de la etapa de acondicionamiento, las señales del vector de sensores deben ser digitalizadas y procesadas en línea o almacenadas para análisis futuros. De la etapa del preprocesado de la señal, la cual se refiere a la aplicación de una serie de posibles operaciones a la señal proveniente de las etapas electrónicas para explotar la información que estos datos representasen, se extrae información de la respuesta de los sensores y se preparan los datos para el análisis de patrones multivariantes, convirtiéndose en la primera etapa informatizada, donde los datos son muestreados y almacenados en la memoria del ordenador (Moreno et al., 2009).

A continuación, se describen algunas técnicas de preprocesamiento de datos.

### 1.6.2.1 Escalador estándar (StandardScaler):

Muchos algoritmos de aprendizaje automático funcionan mejor o convergen más rápido cuando las características están en una escala relativamente similar y / o cerca de la distribución normal.

StandardScaler da como resultado una distribución con una desviación estándar igual a 1. La varianza también es igual a 1, porque varianza = desviación estándar al cuadrado. Y 1 al cuadrado = 1. StandardScaler hace la media de la distribución 0. Alrededor del 68% de los valores estarán entre -1 y 1 (Hale, 2019).

***z = Estandarizacion***

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

***$\mu = media$***

$$\mu = \frac{1}{N} \sum_{i=1}^N (x_i) \quad (2)$$

***$\sigma = desviación\ estándar$***

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3)$$

### 1.6.2.2 Pre-procesamiento de datos (normalización taxi o Manhattan)

En la distancia Manhattan la distancia entre dos puntos, es la suma en valor absoluto de las diferencias de sus coordenadas cartesianas. La Figura 9 muestra cómo pueden existir varios caminos a dos puntos usando Manhattan, pero solo uno y el más corto por Euclídea (Pravin, 2018).

#### Medidas de distancia

Las principales medidas de distancia son:

Euclídea o L2:

$$d_2(x, y) = \sqrt{\sum_{j=1}^J (x_j - y_j)^2} \quad (4)$$

Manhattan o L1:

$$d_1(x, y) = \sum_{j=1}^J |x_j - y_j| \quad (5)$$




Figura 9. Distancias Manhattan y Euclídea. Las líneas roja, azul y amarilla tienen distancia Manhattan 12, la menor posible. La verde tiene distancia Euclídea 8.49 (Pravin, 2018).

## 1.7 Métodos de reconocimiento de patrones e Inteligencia artificial IA

Un subcampo de la IA que ha ganado auge en años recientes es el aprendizaje computacional (machine learning), donde un sistema aprende a ejecutar tareas, ya sea a partir de ejemplos o mediante prueba y error. Los modelos llamados redes neuronales están inspirados en una forma simplificada del funcionamiento de las neuronas. En la actualidad, las redes neuronales profundas (con gran número de células bajo un orden jerárquico), han sido muy exitosas en tareas de alta complejidad, como la identificación de objetos en imágenes y el reconocimiento del habla humana (Pérez & Rentería Rodríguez Miguel, 2018).

El reconocimiento de patrones se refiere a los medios por los cuales se puede interpretar el mundo. Es la ciencia que se ocupa de los procesos sobre ingeniería, computación y matemáticas relacionados con objetos físicos y/o abstractos, con el propósito de extraer información que permita establecer propiedades de o entre conjuntos de dichos objetos (Ochoa, 2011).

### 1.7.1 Análisis de componentes principales (PCA)

PCA es una herramienta para encontrar patrones en datos de alta dimensión. Cada componente principal ( $Z_i$ ) se obtiene por combinación lineal de las variables originales. Se pueden entender como nuevas variables obtenidas al combinar una determinada forma las variables originales. La primera componente principal de un grupo de variables ( $X_1, X_2, \dots, X_p$ ) se ilustra en la figura 9, como una la combinación lineal normalizada de dichas variables que tiene mayor varianza (Amat, 2017)

$$Z_1 = \phi_{11} * X_1 + \phi_{21} * X_2 + \phi_{p1} * X_p \quad (6)$$

La combinación lineal sea normalizada implica que:

$$\sum_{j=1}^p \phi_{j1}^2 = 1 \quad (7)$$

Los términos  $\phi_{11}, \dots, \phi_{1p}$  reciben en el nombre de pesos y son los que definen a la componente.  $\phi_{11}$  es el peso de la variable  $X_1$  de la primera componente principal. Pueden interpretarse como el peso/importancia que tiene cada variable en cada componente y, por lo tanto, ayudan a conocer qué tipo de información recoge cada una de las componentes. En la figura Dado un set de datos  $X$  con  $n$  observaciones y  $p$  variables, el proceso a seguir para calcular la primera componente principal.




Figura 10. Direcciones son perpendiculares/ortogonales (Amat, 2017)

Una vez calculada la primera componente (Z1) se calcula la segunda (Z2) repitiendo el mismo proceso, pero añadiendo la condición de que la combinación lineal no puede estar correlacionada con la primera componente. Esto equivale a decir que Z1 y Z2 tienen que ser perpendiculares (Amat, 2017).

### 1.7.2 Análisis de clúster AC

El Análisis Clúster, conocido como Análisis de Conglomerados, es una técnica estadística multivariante que busca agrupar elementos (o variables) tratando de lograr la máxima homogeneidad en cada grupo y la mayor diferencia entre los grupos. Es un método estadístico multivariante de clasificación automática de datos. A partir de una tabla de casos-variables, trata de situar los casos (individuos) en grupos homogéneos, conglomerados o clúster, no conocidos de antemano, pero sugeridos por la propia esencia de los datos, de manera que individuos que puedan ser considerados similares sean asignados a un mismo clúster, mientras que individuos diferentes (disimilares) se localicen en clúster distintos (F. Fuente, 2011)

### 1.7.3 Análisis de función discriminantes DFA

El Análisis Discriminante es una técnica estadística que se utiliza para clasificar a distintos individuos en grupos, o poblaciones, alternativos a partir de los valores de un conjunto de variables sobre los individuos a los que se pretende clasificar. Cada individuo puede pertenecer a un solo grupo. Se trata de estudiar la aplicación del análisis discriminante a la clasificación de individuos, en el supuesto de que dichos individuos se puedan asignar solamente a dos grupos a partir de  $k$  variables clasificatorias. El problema fue resuelto por Fisher analíticamente mediante su función discriminante (Crespo, 2013)

La función discriminante de Fisher  $D$  se obtiene como función lineal de los  $k$  variables explicativas  $X$ , es decir:

$$D = u_1X_1 + u_2X_2 + \dots + u_kX_k \quad (8)$$

Se trata de obtener los coeficientes de ponderación  $u_j$  considerando que existen  $n$  observaciones, la función discriminante se puede expresar para ellas:

$$D_i = u_1X_{1i} + u_2X_{2i} + \dots + u_kX_{ki} \quad (9)$$

$D_i$  es la puntuación discriminante correspondiente a la observación  $i$ -ésima

### 1.7.4 Redes Neuronales

En la última década las Redes Neuronales Artificiales (ANN) han recibido un interés particular como una tecnología para minería de datos, puesto que ofrece los medios para modelar de manera efectiva y eficiente problemas grandes y complejos. Los modelos de ANN son dirigidos a partir de los datos, es decir, son capaces de encontrar relaciones (patrones) de forma inductiva por medio de los algoritmos de aprendizaje basado en los datos existentes más que requerir la ayuda de un modelador para especificar la forma funcional y sus interacciones. Las ANN son un método de resolver problemas, de forma individual o combinadas con otros métodos, para aquellas tareas de clasificación, identificación, diagnóstico, optimización o predicción en las que el balance datos/conocimiento se inclina hacia los datos y donde, adicionalmente, puede haber la necesidad de aprendizaje en tiempo de ejecución y de cierta tolerancia a fallos. En estos casos las RNAs se adaptan dinámicamente reajustando constantemente los “pesos” de sus interconexiones (Salas, 2015)

A continuación, se puede ilustra esquemático de una red neuronal.




Figura 11. Ejemplo de una red neuronal totalmente conectada (Ruiz, Basualdo, & Matich, 2001)

### 1.7.5 Máquinas de soporte vectorial

El concepto inicial es de un vector de características en un espacio de entrada, donde un conjunto de vectores es mapeado a una dimensión mayor, sea por la multiplicación

de los productos internos o por un *Kernel* en el caso de los no separables, asegurando la minimización del espacio característico y la maximización del margen, donde los puntos más cercanos a la línea de decisión son los puntos de soporte; las Máquinas de Soporte Vectorial parten de la teoría de minimización de riesgo estructural la cual nos garantiza que el error en el diseño es mínimo (Morales, 2012)




Figura 12. Hiperplanos de separación en un espacio bidimensional de un conjunto de ejemplos separables en dos clases (Morales, 2012)

Dentro de la tarea de clasificación, las SVM pertenecen a la categoría de los clasificadores lineales, puesto que inducen separadores lineales o hiperplanos, ya sea en el espacio original de los ejemplos de entrada, si éstos son separables o cuasi-separables (ruido), o en un espacio transformado (espacio de características), si los ejemplos no son separables linealmente en el espacio original. Estos espacios transformados, normalmente de muy alta dimensión, se hará de forma implícita utilizando las denominadas funciones kernel (Suárez, 2014)

Para las reglas de decisión lineales se usa un dato  $x$ , esta muestra se proyecta a un vector unidad  $W$ , la regla de decisión para la clase 1 es:

$$w^T x - q > 0 \quad (10)$$

Donde  $q$  es una constante, los puntos más cercanos a la línea de decisión se le realiza una proyección ortogonal,  $x_1$  punto de la clase 1 y  $x_2$ , punto de la clase 2, donde se realiza una proyección ortogonal a  $w$  para determinar quién está más cerca de la línea de decisión. Se muestra que las clases se proyectan ortogonalmente a la línea  $W$ , así se puede ver los puntos de entrenamiento más cercano a la línea  $q$ , con los puntos  $x_1$ ,  $x_2$  y el mínimo positivo  $p$ .

$$\varphi^T x_1 = q + p \quad \varphi^T x_2 = q - p \quad (11)$$

Ahora se define el valor  $L$  como el set de entrenamiento de una clase:

$$L_1 \text{ son los puntos de la clase 1,} \quad (12)$$

$$\varphi^T x_1 - q \Rightarrow p$$

$$L2 \text{ son los puntos de la clase 2,} \quad (13)$$

$$\varphi^T x_1 - q = < p$$

Ahora se hallarán dos cosas:

- los puntos los más cercanos a q, a estos se le llaman vectores de soporte.
- Un vector ortogonal que proyecte los puntos de soporte la mayor separación posible.

Ahora se mira el comportamiento de las clases en el espacio de entrada, se define  $\varphi = w / \|w\|$ , en el vector unidad en la dirección w y se reemplaza en la ecuación

$$\left(\frac{w}{\|w\|}\right)^T x_1 - q \geq p \quad (14)$$

$$\left(\frac{w}{\|w\|}\right)^T x_2 - q \leq p \quad (15)$$

Se organiza la ecuación.

$$\left(\frac{w}{\|w\|}\right)^T x_1 - q \|w\| \geq p \|w\| \quad (16)$$

$$\left(\frac{w}{\|w\|}\right)^T x_2 - q \|w\| \leq p \|w\| \quad (17)$$

Definimos la constante  $b = -q\|w\|$ , donde se adiciona a W, la magnitud tiene una particular propiedad.

$$\|w\| = \frac{1}{p} \quad (18)$$

Ahora tenemos la ecuación que describe el comportamiento de los puntos.

$$w^T x_1 + b \geq 1 \quad (19)$$

$$w^T x_2 + b \leq 1 \quad (20)$$




Figura 13. Distribución de las clases y su regla de decisión (Morales, 2012)

### **1.7.6 Random Forest**

Random Forest es un método versátil de aprendizaje automático capaz de realizar tanto tareas de regresión como de clasificación. También lleva a cabo métodos de reducción dimensional, trata valores perdidos, valores atípicos y otros pasos esenciales de exploración de datos. Es un tipo de método de aprendizaje por conjuntos, donde un grupo de modelos débiles se combinan para formar un modelo poderoso. En Random Forest se ejecutan varios algoritmos de árbol de decisiones en lugar de uno solo. Para clasificar un nuevo objeto basado en atributos, cada árbol de decisión da una clasificación y finalmente la decisión con mayor “votos” es la predicción del algoritmo (González, 2018).

### **1.8 Proceso de fermentación del grano de cacao**

La fermentación del grano de cacao es un proceso esencial para el desarrollo apropiado de los precursores del sabor. Esta etapa tiene dos objetivos principales: (1) Remover el mucilago, permitiendo la aireación del grano durante la fermentación y facilitar el proceso de secado; (2) Proveer el calor y el ácido acético necesario para inhibir la germinación. El método y tiempo de fermentación, la frecuencia de remoción del grano; así como las condiciones atmosféricas de la zona afectan la calidad del cacao (Afoakwa et al., 2008)

Los granos de cacao tienen un sabor ácido desagradable, por lo que para obtener cacao con el color y el sabor del chocolate deben ser fermentados, tostados y secados. En el proceso de fermentación participan los microorganismos que se encuentran naturalmente en los granos, de entre los cuales actúan primeramente las levaduras. Posteriormente actúan las bacterias lácticas y, finalmente, intervienen las bacterias acéticas, los Bacillus y las enterobacterias. Esta fermentación es esencial tanto para modificar los granos, eliminando el mucílago, como para preparar el grano que requieren las enzimas encargadas de modificar su color, sabor y olor, produciendo también compuestos de sabor. La fermentación es una etapa del procesamiento del grano de cacao, que requiere aún de investigación, ya que hasta la fecha sigue siendo bastante empírica. Una fermentación en condiciones controladas permitirá obtener cacao de buena calidad y de características homogéneas (Wacher, 2011).

Ningún compuesto nuevo es puesto en evidencia durante la fermentación. Solo los contenidos de compuestos presentes en las almendras frescas varían en función del tiempo de tratamiento. Los contenidos de alcoholes y ácidos pasan por un máximo, respectivamente el 1er día y el 3er día de fermentación y posteriormente disminuyen. Los contenidos en aldehídos aumentan regularmente durante el



proceso de fermentación. Los alcoholes registran un ligero incremento a las 24 horas, posteriormente presenta un comportamiento estable para finalmente disminuir al final del proceso. El contenido de cetonas permanece estable durante los tres primeros días de fermentación y disminuye al final de la misma. La figura 14 muestra la trazabilidad en la evolución de compuestos volátiles durante la fermentación del cacao.




Figura 14. Evolución de las familias de compuestos volátiles principales durante la fermentación en cacao fresco (Castañeda & Rodríguez Jacobo, 2016)

## 2 SELECCIÓN Y ADECUACION DE MUESTRAS DE CACAO

A continuación, se describe el proceso de fermentación de cacao, motivo del análisis de la investigación, se documenta la trazabilidad desde la selección de la finca, Identificación de material, corte de la mazorca, adecuación de muestras de cacao e implementación de protocolo emitido por FEDECACAO para lograr una fermentación de calidad.

Gracias al acompañamiento del personal experto-extensionista por parte de FEDECACAO en Norte de Santander, se logró seleccionar algunas fincas productoras tecnificadas en el proceso de producción, como la finca Miraflores y finca el Amparo.

### 2.1 Selección del material de cacao

Debido la etapa de producción de cosecha se seleccionó la finca el Amparo, Vereda Restauración, ubicada en el municipio de Puerto Santander, Cúcuta departamento de Norte de Santander, identificando el Clon motivo de investigación él ICS-95 siendo un material exclusivo de olor y aroma.

La investigación inicia con la identificación de surcos con material ICS-95, origen Trinitario. En la figura 15, se ilustra el proceso de corte con tijera, de la mazorca de cacao para dar inicio al proceso de recolección del producto.



Figura 15. Corte de mazorca de cacao ICS-95 (Fuente autor)

En la figura 16, ilustra surco del material y mazorcas para iniciar la recolección del material ICS-95.



Figura 16. Surco material ICS 95. Finca el Amparo, vereda restauración, Cúcuta.

En la figura 17, se realiza medición de altitud del cultivo de cacao seleccionado para el desarrollo de la investigación, se utiliza un GPS marca Garmin, obteniendo una medida de 63m sobre el nivel del mar.



Figura 17. Medida altitud de la plantación de cacao, con GPS Garmin. (Fuente autor).

A continuación, se muestran 20 mazorcas selectas de material ICS-95, para iniciar el proceso de extracción de masa de cacao.



Figura 18. Mazorcas de cacao clon ICS-95 (Fuente autor).

Se procede a partir la mazorca de cacao, utilizando mazo, esta técnica permite conservar las almendras de cacao.



Figura 19. Partida de mazorca con mazo (Fuente autor).

En la figura 20, se puede observar las almendras de cacao al interior de la mazorca del material ICS-95.



Figura 20. Almendras de cacao

En la figura 21, se ilustra la placenta de la almendra de cacao.



Figura 21. Placenta del cacao.

Una vez realizado el proceso de apertura de la mazorca, se extraen las almendras y se forma la masa de cacao, se procede a pesar los primeros 800 gramos debido a la escala máxima del peso, en la figura 22 se observa la masa de cacao o cacao en baba.



Figura 22. Cacao ICS-95 en baba 800g.

Se realizó partida de 20 mazorcas clon ICS 95, como resultado se obtuvo 2,225 Kilogramos de masa de cacao.

## **2.2 Adecuación de muestras de cacao en el proceso de fermentación.**

El método para iniciar el proceso de fermentación se rige al protocolo establecido por FEDECACAO, para el proceso postcosecha.

### **2.2.1 Protocolo de fermentación del cacao**

En este proceso se desarrolla el sabor y aroma del producto y contribuye a formar un grano (hinchado), de color marrón y de buena apariencia.

- Primer volteo: 48 horas
- Segundo volteo: 24 horas (72 horas)
- Tercer volteo: 24 horas (96 horas)
- Cuarto volteo: 24 horas (120 horas)
- Quinto volteo: 24 horas (144 horas)

Nota: tapar la masa con hojas de plátano, encima costales limpios o un plástico negro debidamente limpio. No se deben mezclar granos provenientes de mazorcas cosechadas ni con un da de diferencia.

### **2.2.2 Protocolo de secado del cacao**

El presente apartado se relaciona para tener conocimiento que después de la etapa de fermentación continua la etapa de secado, para la presente investigación no se realiza este análisis.

El secado de cacao se lleva a cabo inmediatamente después de que termina la fermentación, su fin es reducción de humedad al grano de cacao, ya que después de fermentado queda con humedad del 55%, por tanto, debe bajar hasta obtener del 7% al 8% de humedad a final del proceso de secado.

- Primer día: tres (3) horas de sol, luego la masa se recoge.
- Segundo día: cuatro (4) horas de sol, luego se recoge.
- Tercer, cuarto y quinto día, todo el día recibiendo radiación solar

Se debe realizar remoción de la masa de cacao cada (2) horas, al menos en 4 y 5 remociones diarias.

Nota: Se refiere a recoger, la acción de amontonar con la finalidad de permitir completa fermentación en caso de que exista algún grano al cual aún le falte.

### **2.2.3 Fermentación material ICS-95 sano.**

Siguiendo el protocolo de fermentación emitido por FEDECACAO, una vez realizado el proceso de extracción de las almendras de cacao se procede a ingresar la masa de cacao al interior del barril fermentador, construido en madera, su forma cilíndrica permite realizar fácil volteo de masa. Durante las primeras 48 horas la masa de cacao permanece estática, pasada las 48 horas se inicia el periodo de volteo 1 vez cada 24 horas, hasta cumplir 144 horas donde finaliza el proceso de fermentación. En la figura 23, se observa el barril de fermentación de masa de cacao.



Figura 23. Barril de madera para fermentación de masa de cacao.

La figura 24, muestra la masa de cacao al inicio del proceso de fermentación.



Figura 24. Fermentación en barril material ICS-95

En la figura 25, se observa la masa de cacao pasado 72 horas después del inicio del proceso de fermentación, listas para ser sometidas al segundo volteo de masa, en este caso se debe tapar y girar el barril.



Figura 25. Fermentado 72horas ICS-95

Finalmente, en la figura 26, podemos observar la masa de cacao pasado 144horas de fermentación.



Figura 26. Fermentado 144horas ICS-95

#### 2.2.4 Fermentación material ICS-95 infectado con monilia

Como parte del desarrollo de la investigación se recolectaron algunas mazorcas infectadas por monilia, debido a que este tipo de granos afectan considerablemente la calidad del producto enmarcado en el olor y sabor. La figura 27 ilustra, mazorca de cacao infectado por monilia.



Figura 27. Cacao enfermo con monilia.

Para el experimento se seleccionaron 20 mazorcas, de las cuales 8 se encuentran infectadas por monilia y 12 en estado sano, el fermentado se realiza en cajón de madera e iniciamos el protocolo establecido por FEDECACAO, algunas almendras se muestran germinadas. La masa total de cacao obtenida 2215 gramos.



Figura 28. ICS95 20 Mazorcas afectadas-monilia y germinadas.

La figura 29, muestra la finalización del proceso de fermentación de la masa de cacao infectada a las 144 horas.





Figura 29. Fermentado ICS95 con monilia 144h.

Otro aspecto para el análisis de la investigación es someter la masa de cacao a un periodo prolongado de fermentado, es decir lograr un sobrefermentado de masa de cacao, la figura 30 muestra aspecto de almendras de cacao en esta fase.



Figura 30. Sobrefermentado ICS95 288h

### 3 EQUIPO DE MEDICIÓN PARA LA DETECCIÓN Y CLASIFICACIÓN DE VOLÁTILES

El presente capítulo documenta las características técnicas, partes físicas y electrónicas, que conforman el equipo de olfato electrónico o nariz electrónica *CANOSE*, cuyo objetivo es medir y clasificar volátiles emitidos por las almendras de cacao en el proceso de fermentación.

#### 3.1 Diagrama de bloques del sistema de olfato electrónico *CANOSE*

A continuación, se ilustra el diagrama de bloques que conforma el sistema de medición de olfato electrónico:

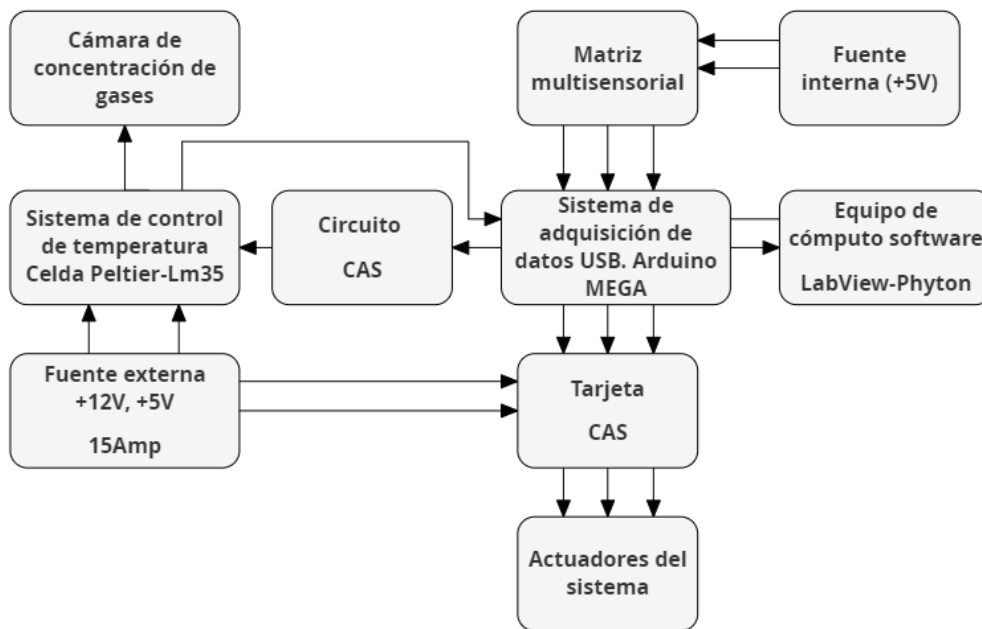


Figura 31. Diagrama de bloques del equipo de medición multisensorial.

Fuente Autor

La figura 32, se observa el desarrollo final de la nariz electrónica denominada CANOSE, las partes externas que la integran son, cámara de concentración de gases, cámara de medición de volátiles (matriz de sensores), equipo de cómputo asociado al software de interacción y operación, y maleta plegable para fácil transporte.




Figura 32. Sistema de olfato electrónico o nariz electrónica CANOSE (Fuente autor)

### 3.1.1 Cámara de concentración de gases

La función principal de la cámara de concentración es, alojar las muestras de cacao, generar el espacio de cabeza, conservar la hermeticidad y temperatura controlada de la muestra.

La estructura es tipo cilíndrico, ajuste con tapa y sello hermético.

Las dimensiones son radio=5cm, altura=10cm, dispone de un volumen aproximado de 0.785 litros, material hierro con recubrimiento de pintura electrostática externa.

La cámara cuenta con dos resortes externos que se anclan a una base en acero inoxidable, el cual tiene como función, sujetar el conjunto sensor-actuador del sistema de control de temperatura. El sistema de anclaje, permite que la estructura se pueda desmontar fácilmente, lo que facilita el procedimiento de limpieza y mantenimiento.

La tapa presenta dos perforaciones que permiten la extracción de los volátiles emitidos, con conexión de cable (racor), rosca 1/4 de pulgada.



Figura 33. Cámara de concentración de gases.

### 3.1.2 Sistema de control de temperatura para la cámara de concentración

El control de temperatura implementa como actuador, un novedoso sistema de calentamiento termoeléctrico, basado en el efecto Seebeck, conformado por una celda de peltier, este dispositivo tiene la capacidad de suministrar una temperatura específica que permite mantener las muestras en un ambiente controlado para la medición.

La figura 34, ilustra la celda de Peltier como dispositivo actuador del sistema de calentamiento para el control de temperatura de la cámara de concentración de gases.



Figura 34. Celda de Peltier como elemento de generación de calor para calentar las muestras de cacao

### 3.1.2.1 Características de la celda Peltier

- Modelo: TEC1-12706
- P Bismuto
- N Teluro
- Tamaño: 40\*40\*3.8mm
- Resistencia: 2.1~2.5Ohm
- Cantidad de termopares: 127
- Diferencia de temperatura máxima entre caras: 69 °C
- Máxima temperatura de operación cara caliente: 83 °C
- Mínima temperatura de operación cara fría: -55°C
- Voltaje: DC 12V
- Voltaje Max: DC 15V
- Qcmax 58-60W
- Corriente aproximada 5A.

### 3.1.2.2 Sensor de temperatura LM35

Como elemento sensor de temperatura se implementa el circuito integrado LM35, la salida del dispositivo es lineal, en la figura 35 la instalación del sensor sobre la base de la cámara de concentración de volátiles. Cada grado Celsius, equivale a una variación en la señal de salida de 10 mV. El rango de medición se define desde -55 grados Celsius, hasta 150 °C. El control de temperatura de la cámara se establece con una consigna 33 grados Celsius.




Figura 35. Sensor de temperatura LM35 instalado en cámara de concentración de volátiles.

### 3.1.2.3 Características circuito integrado LM35

- Fabricante: National Semiconductor (TI)
- Directamente calibrado en grados Celsius
- Exactitud de  $\pm 0.5$  °C a temperatura ambiente (25 °C), y  $\pm 0.8$  °C en el rango completo
- Bajo autocalentamiento: 0.08 °C con aire en reposo
- Lineal. Salida de 10 mV/°C
- Voltaje de operación: 4 V a 30 V
- Consumo de corriente: < 60  $\mu$ A típico
- Baja impedancia de salida: 0.1  $\Omega$  con carga de 1 mA
- Temperatura de operación: 0 °C a +100 °C
- Encapsulado: TO-92

### 3.1.3 Cámara de medición de volátiles

La matriz multisensorial es el equivalente a los receptores olfativos a nivel biológico, es uno de los módulos principales que conforman el equipo de olfato electrónico *CANOSE*, está conformado por 10 sensores de gases de la referencia MQ, los cuales tienen la posibilidad de detectar una variedad de compuestos volátiles.

Los sensores se encuentran alojados en una cámara de medición con las siguientes dimensiones, 10 cm de largo, 7 cm de ancho, 3cm de alto para un volumen aproximado de 210 cm<sup>3</sup>, el material acero inoxidable y dispone de dos terminales para permitir el flujo de aire, con conexión de cable (racor), rosca 1/4 de pulgada.

La figura 36, ilustra cámara de medición de compuestos volátiles, incluye dos terminales en sus extremos cuya función es el ingreso y salida del volátil, como medio de protección para los sensores, la cámara cubierta por una estructura en acrílico.




Figura 36. Cámara de medición de volátiles.

Los sensores son de tipo electroquímicos, varían la resistencia interna cuando se exponen a determinados gases, internamente posee un calentador encargado de aumentar la temperatura interna y con esto el sensor pueda reaccionar con los gases provocando un cambio en el valor de la resistencia.

Teniendo en cuenta algunos tipos de volátiles emitidos durante el proceso de fermentado según estudios realizados, e información suministrada en el estado del arte del presente proyecto, se proceden a seleccionar los siguientes sensores.

La figura 37, ilustra ejemplo de tres tipos de sensores de gases con diferente encapsulado o diseño, todos en general poseen un recubrimiento metálico donde está alojado el sensor.




Figura 37. Sensores de gas fabricante MQ (Llamas, 2016).

Referencia	Sustancias detectadas	Calentador
MQ-4	Metano, gas natural comprimido (GNP)	5V
MQ-135	Benceno, alcohol, humo, calidad del aire	5V
MQ-2	Metano, butano, GLP, humo	5V
MQ-8	Hidrógeno	5V
MQ-5	Gas natural, GLP	5V
MQ-3A	Alcohol, Etanol, humo	5V
MQ-6	Butano, GLP	5V
MQ-3	Alcohol, Etanol, humo	5V
MQ-7	Monóxido de carbono	Alternado 5V y 1.4V
MQ-9	Monóxido de carbono, gases inflamables	Alternado 5V y 1.5V

Tabla 3. Referencias de sensores de gases MQ que hacen parte de la cámara de medida (Llamas, 2016)

### 3.1.4 Sistema de adquisición de datos

Se implementa el uso de la tarjeta de adquisición hardware arduino 2560, debido al número de canales y terminales de entrada/salida. La comunicación se establece mediante puerto USB a PC, el sistema es flexible en programación y es compatible con diversos tipos de software como LabView, Matlab, Python. Para el desarrollo del sistema de olfato electrónico la comunicación se realiza con el software LabView, y uso de librerías MakerHub.

La figura 38, muestra un diagrama de bloque, donde se etiqueta la conexión de los sensores MQ, relacionado desde el terminal de entrada analógico A0 hasta el terminal A10, el terminal A10, recibe la señal proveniente del sensor de temperatura LM35. Para el accionamiento de las tres válvulas y bomba, se dispone de los terminales pin 4 al pin 7, conectados a la tarjeta CAS de Relé. El terminal 12, se conecta la tarjeta IRF520, para realizar el control de temperatura asociado a la celda de Peltier.

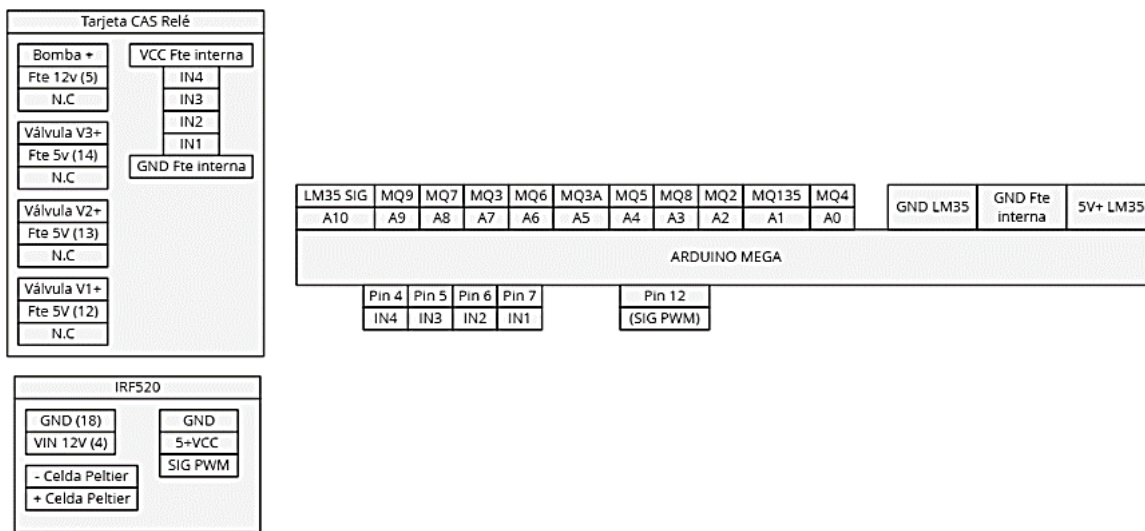


Figura 38. Diagrama de conexión Arduino MEGA con el sistema CANOSE (Fuente autor).

### 3.1.5 Tarjeta CAS: Circuito acondicionamiento de señales salida relé

La función principal del circuito acondicionador de señal, es conmutar la señal digital de baja potencia, proveniente de las salidas de la tarjeta de adquisición Arduino Mega, y acondicionarlas a una señal digital de alta potencia, esta acción permite



realizar activación de los actuadores del sistema, como son las electroválvulas solenoides, que darán apertura o cierre del flujo de aire.

La figura 39, relaciona la tarjeta de acondicionamiento de señal, encargada de conmutar las tres válvulas del sistema y bomba de flujo de aire.



Figura 39. Circuito acondicionador de señal, salida relé (Fuente autor).

### 3.1.6 Tarjeta CAS: Circuito de acondicionamiento de señal Mosfet IRF520

El sistema integra una segunda tarjeta denominada circuito CAS, conformada por un Mosfet IRF520 MOS Módulo de controlador, la función principal es activar o desactivar el sistema termoeléctrico basado en celda Peltier, será controlado por medio de una señal por modulación de ancho de pulso PWM, de esta forma será posible mantener la temperatura de la cámara en un valor deseado.




Figura 40. Tarjeta MOSFET, activación sistema de temperatura por PWM (Fuente autor).

Finalmente, el sensor Lm35, es el encargado de enviar la información de temperatura de la cámara de concentración a una entrada análoga del sistema de adquisición de datos.

### 3.1.7 Fuente de alimentación externa

Suministra energía para alimentar los actuadores del sistema, salida 5V para activación de electroválvulas solenoides y 12V, celda de peltier.

Identificación cableada:

- 1.- Red +5VDC (Suministro +5 Volts) 15 Amperios.
- 2.- Black GND (Tierra)
- 3.- Black GND (Tierra)
- 4.- Yellow +12VDC (Suministro + 12Volts) 25 Amperios.

### 3.1.8 Fuente de alimentación interna

Fuente de instrumentación marca MEAN WELL 5Voltios 10amperios, suministra energía a sistema multisensorial y tarjetas de acondicionamiento de señal, CAS, sensor LM35, voltaje 5VDC+.



Figura 41. Fuente de instrumentación interna (Fuente autor).

### 3.1.9 Válvulas

Se dispone de tres válvulas solenoides, que serán las encargadas de controlar el flujo de aire, durante el proceso de captura de data.



Figura 42. Válvulas solenoides normalmente cerradas (Fuente autor).

Características voltaje de operación de 5voltios a 12 Voltios.

Aplicación: para aire.

Configuración: Válvula normalmente cerrada NC.

Tipo: solenoide.

Marca: KTC

Referencia: 309 243

### 3.1.10 Bomba de diafragma

La función principal es suministrar el flujo de aire en cada una de las etapas de ejecución de captura de data. El flujo circula en lazo cerrado arrastrando los volátiles emitidos en la cámara de concentración de gases direccionándolos hacia la cámara de medición de volátiles.



Figura 43. Bomba de diafragma para flujo de aire (Fuente autor).

#### **Especificaciones:**

Modelo: R385

Material: Plástico

Voltaje 12V cuando: la potencia es de 5W / H

Diámetro de salida: Interior: 6 mm / 0.24 "

Exterior: 9 mm / 0.35 "

Voltaje de funcionamiento- potencia de trabajo: DC6-12V 5W / H

Caudal máxima succión: 1.6-1.7LMin 1.2M

Se puede usar para agua o aire.

Tipo: bomba de diafragma DC

## **4 SOFTWARE DE SUPERVISION, CONTROL Y ADQUISICION DE DATOS DEL SISTEMA DE OLFATO ELECTRÓNICO**

El presente capítulo documenta las partes que conforman el diseño de la interfaz gráfica en lenguaje de alto nivel, bajo plataforma de software LabVIEW 2018. Dicho aplicativo se caracteriza por tener una Interfaz Gráfica de Usuario (GUI) interactiva con el usuario, permitiendo realizar la visualización del proceso, adquisición y almacenamiento de data proveniente de la matriz de sensores de gases. Integra un módulo Proporcional-Integral-Derivativo PID, para realizar el control de temperatura asociado a la cámara de concentración de volátiles, también ofrece al usuario la posibilidad de ingresar los tiempos requeridos para la fase de limpieza de la cámara de concentración y medición, tiempo de concentración de volátiles, tiempo de adquisición y finalmente tiempo de extracción. Los datos adquiridos se exportan en formato xlsx Excel.

La figura 44, ilustra las partes que conforman el aplicativo de software, para la ejecución del programa es importante verificar la correcta conexión del cable USB desde el equipo de cómputo a la nariz electrónica CANOSE, posteriormente desde la interfaz gráfica seleccionar el puerto serial.

## 4.1 Partes que conforman el aplicativo de software

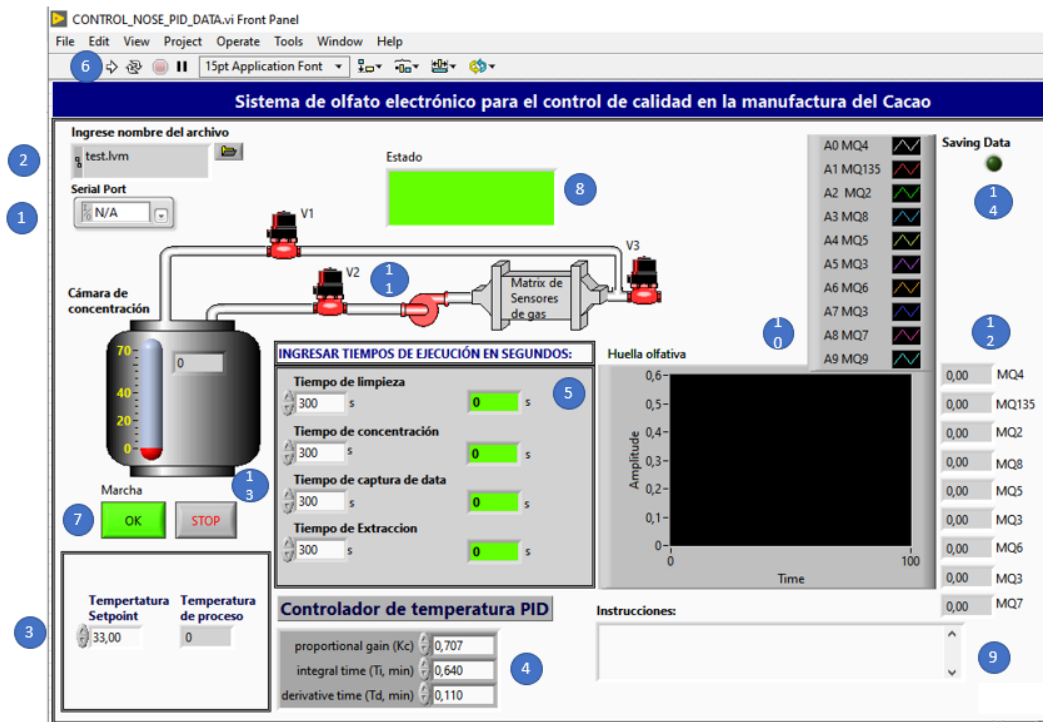


Figura 44. Partes que conforma el aplicativo de software para el control automático del sistema de olfato electrónico (Fuente autor).

Descriptor	Protocolo de ejecución
1. Menú desplegable para la selección del puerto USB.	Selección del puerto USB asignado por el computador.
2. Casilla para asignación del nombre de la data.	Ingrese el nombre con el que desea guardar la data adquirida.
3. Temperatura Setpoint.	Ingrese el valor numérico de la temperatura deseada asociada a la cámara de concentración. Observe que el software dispone de un indicador numérico asociado denominado: Temperatura de proceso, y a su vez dispone de un instrumento virtual tipo termómetro, el usuario podrá visualizar la temperatura en tiempo real de la cámara de concentración de muestras.
4. Módulo para el control de temperatura PID.	El usuario tiene la posibilidad de ingresar las constantes de sintonización asociadas al control PID. Los tiempos en minutos.

	<p><i>Ganancia proporcional <math>k_c =</math></i>  <i>Tiempo integral <math>T_i =</math> minutos</i>  <i>Tiempo derivativo <math>T_d =</math> minutos</i></p>
<p>5. Tiempo de ejecución para el control automático</p>	<p>El usuario ingresa los tiempos adecuados para la ejecución de la adquisición de la data en los que se incluye:</p> <p style="padding-left: 40px;">Tiempo de limpieza: 300s.</p> <p>Durante el tiempo de limpieza es importante abrir tapa asociada a la cámara de concentración.</p> <p>En esta etapa las válvulas V1, V2, V3, y bomba, están en estado activo.</p> <p>Cuando el tiempo sea 290s, ingrese la muestra en la cámara de concentración y cierre la tapa.</p> <p style="padding-left: 40px;">Tiempo de concentración: 300s.</p> <p>Tiempo estimado para obtener el espacio de cabeza.</p> <p>En esta etapa las válvulas V1, V2, V3, y bomba, están en estado apagado.</p> <p style="padding-left: 40px;">Tiempo de captura de datos: 300s.</p> <p>Inicia flujo de aire en lazo cerrado de forma continua, la matriz de sensores responde ante los diferentes volátiles asociados, creando la huella olfativa de la muestra.</p> <p>En esta etapa las válvulas V1, V2, V3, y bomba, están en estado activo.</p> <p style="padding-left: 40px;">Tiempo de extracción: 300s.</p> <p>En esta etapa se inicia el tiempo de recuperación de los sensores de gases</p>

	<p>para tratar de retornar a la línea base o estado inicial.</p> <p>Iniciado la fase de extracción es importante abrir la tapa de la cámara de concentración y sacar las muestras, esto permite una mayor recuperación de los sensores.</p> <p>En esta etapa las válvulas V1, V2, V3, y bomba, están en estado activo.</p> <p>Tiempo promedio de la ejecución por toma de muestra 20 minutos.</p> <p>Se sugiere asignar un valor de 300 segundos a cada parámetro tiempo asociado, esto con motivo obtener data óptima para el análisis de datos, con estos tiempos se logra mantener la línea base de la respuesta de los sensores.</p> <p>El usuario podrá visualizar el estado del tiempo en los indicadores numéricos asociados.</p>
6. Botón ejecución del programa	Una vez ingrese los valores de tiempo y control de temperatura, ejecute el programa.
7. Botón de marcha	Proceda a iniciar el sistema oprimiendo el botón marcha.
8. Ventana estado	<p>Informará al usuario el estado de operación del sistema.</p> <p>Estos son:</p> <p>Estado activo Limpieza Cámara Concentración de volátiles Captura de data Extracción</p>
9. Ventana de instrucciones	El usuario tiene la posibilidad de visualizar mensajes alusivos procedimentales para la correcta ejecución de la toma de datos.

10. Graficador de señales	Graficador numérico, permite visualizar la respuesta de cada sensor asociado a la matriz multisensorial – huella olfativa.
11. Diagrama de proceso	Ilustración diagrama de proceso.  Partes:  Válvulas V1, V2, V3, Bomba. Cámara de concentración. Matriz de sensores de gases o matriz multisensorial. Ducto flujo de aire.
12. Indicadores de voltaje	Indicador tipo numérico que permite testear el valor de los voltajes suministrados por cada sensor de gas.
13. Botón stop	Aborda o finaliza el programa, cabe resaltar que el proceso se realiza de forma automática lo cual finaliza la adquisición sin necesidad de pulsar el botón stop.
14. Botón indicador almacenamiento de data	Cuando el indicador se activa hace referencia al almacenamiento de datos en un archivo Excel.

Tabla 4. Descripción de las partes que conforman el aplicativo de software para el control automático de la nariz electrónica CANOSE.

#### 4.2 Protocolo de adquisición

Los tiempos de ejecución para la adquisición y almacenamiento de datos se definen de manera que se garantice la línea base de la señal, en este caso para el tiempo de limpieza se requieren 300 segundos, seguido inicia el tiempo de concentración de volátiles, con una duración de 300 segundos, posterior se activa el sistema para inyección de flujo de aire en lazo cerrado e inicia la fase de captura de data, por un periodo de 300 segundos, finalmente el sistema ingresa en la fase de tiempo de extracción para retornar a condiciones iniciales, por un periodo de 300 segundos. El tiempo de ejecución por muestra es de 1200 segundos o 20 minutos.

#### 4.3 Librerías aplicativo de software

Para la correcta ejecución del aplicativo de software se requiere tener instalado las siguientes librerías:

El Módulo LabVIEW Datalogging and Supervisory Control (DSC) 2018.  
VI Package Manager (VIPM) de JKI



#### 4.4 Ajuste de ganancia para el sistema de control Proporcional-Integral-Derivativo PID.

El control de temperatura se aplica a la cámara de concentración de gases, para lograr la identificación o función de transferencia del sistema térmico, se procede a implementar técnicas de control en lazo abierto.

La figura 45, ilustra la respuesta del sistema ante una entrada escalón definida en 4.8 Voltios Dc aplicado al proceso de temperatura, en lazo abierto. De la curva de proceso, se puede identificar algunos valores importantes al momento de efectuar los métodos de caracterización, de la respuesta del sistema y conociendo la entrada es posible identificar el modelo dinámico de la planta.

Se implementará el método de dos puntos de Alfaro, el cual se basa en otros procedimientos similares que toman dos puntos de la curva de reacción, diferenciándose únicamente en la selección de los dos instantes en que la respuesta del modelo se hace coincidir con la del proceso real.

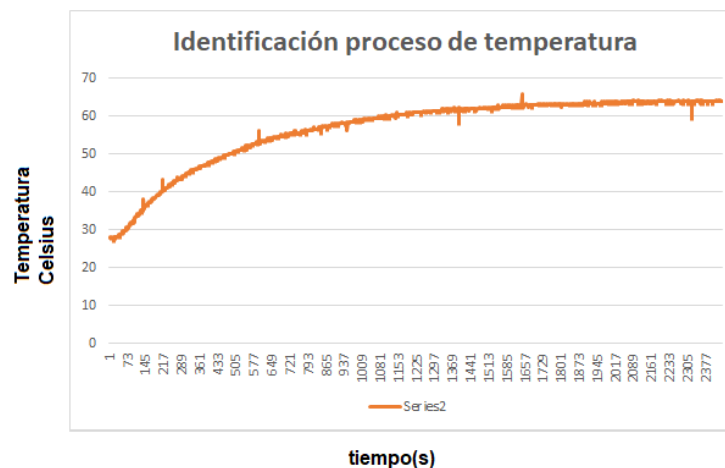


Figura 45. Curva de reacción cámara de concentración (Fuente autor)

Se aplica una señal de entrada escalón unitario del 40% del voltaje total de 12 Volts DC suministrado a la celda de Peltier, el calor es transferido al conjunto sensor y cámara de concentración.

Las ecuaciones generales para el método de dos puntos se definen en la figura 46, con el fin de identificar un modelo de primer orden más tiempo muerto con base en los tiempos requeridos para alcanzar dos puntos específicos en la curva de reacción del proceso.

<b>Tabla N° 1 - Constantes para la identificación de los modelos de primer orden más tiempo muerto</b>						
<b>Método</b>	<b>%p<sub>1</sub> (t<sub>1</sub>)</b>	<b>%p<sub>2</sub> (t<sub>2</sub>)</b>	<b>A</b>	<b>b</b>	<b>c</b>	<b>d</b>
<b>Alfaro</b>	250	75.0	-0.910	0.910	1.262	-0.262
<b>Bröida</b>	28,0	40.0	-5.500	5.500	2.800	-1.800
<b>Chen y Yang</b>	33,0	67.0	-1.400	1.400	1.540	-0.540
<b>Ho et al.</b>	35.0	85.0	-0.670	0.670	1.300	-0.290
<b>Smith</b>	28.3	63.2	-1.500	1.500	1.500	-0.500
<b>Vitecková et al.</b>	33.0	70.0	-1.245	1.245	1.498	-0.498

Figura 46. Constantes para identificación de los modelos de primer orden más tiempo muerto (Alfaro Ruíz, 2011).

Se puede identificar el porcentaje asignado para los puntos p<sub>1</sub> y p<sub>2</sub>, que corresponden a dos valores del cambio en la respuesta del sistema ante una entrada escalón. t<sub>1</sub> y t<sub>2</sub> son los tiempos requeridos para alcanzar estos dos valores, entonces los parámetros de un modelo de primer orden más tiempo muerto se pueden obtener de:

$$\tau = at_1 + bt_2; \text{ constante de tiempo} \quad (21)$$

$$t_m = ct_1 + dt_2; \text{ tiempo muerto} \quad (22)$$

$$t_m = ct_1 + dt_2; \text{ tiempo muerto} \quad (23)$$

$$k_p = \frac{\Delta y}{\Delta u} \quad (24)$$

La Función de transferencia en forma normalizada:

$$G_P(s) = \frac{k_p e^{-t_m s}}{\tau s + 1} \quad (25)$$

#### 4.4.1 Caracterización del sistema

La señal de entrada en lazo abierto con voltaje alimentación aplicado a la celda de peltier es de 4.8 VDC, tiempo total de la prueba fueron 2448 segundos, equivalente a 40.8 minutos; Teniendo en cuenta los datos recopilados podemos identificar los siguientes parámetros:

1. Temperatura ambiente promedio= 28.09 °C (Offset)
2. Temperatura estado estable= 64,01 °C

Tiempo en alcanzar el estado estable= 40.8 minutos

La señal de offset está relacionada con la temperatura ambiente, no permite que el sistema inicie desde 0 °C.

La temperatura de entrada del sistema, se referencia con respecto al valor suministrado por el fabricante:




Figura 47. Gráfico de temperatura vs Voltaje en celdas de Peltier (Carlson, 2018)

Para un valor de 4.8 DC Voltios aproximadamente se obtiene una temperatura de 37°C.

#### 4.4.1.1 Procedimiento cálculo de la ganancia en lazo abierto

1. Cálculo de la ganancia del sistema en lazo abierto  $K_p$ :

$$\begin{aligned}
 K_p &= \Delta y / \Delta x & (26) \\
 \Delta x &= 37 - 28.09 = 8.91^\circ\text{C} \\
 \Delta y &= 64.01 - 28.09 = 35.92^\circ\text{C} \\
 K_p &= \Delta y / \Delta x = 35.92 / 8.91
 \end{aligned}$$

**$K_p = 4.03$**

2. Aplicando el Método de dos puntos por Alfaro según figura 46, tenemos los siguientes resultados:

% $P_1(t_1)$  con el 25% del valor de salida.

Regla de tres:

$$\begin{aligned}
 \Delta y & \text{-----} 100\% \\
 \text{Amp1} & \text{----} 25\%
 \end{aligned}$$

Entonces: 35.92°C -----100%  
 Amp1-----25%

$$\begin{aligned} \text{Amp1} &= (35.92^\circ\text{C} \cdot 25) / 100 = 8.98^\circ\text{C} \\ \text{Amp1} &= 8.98^\circ\text{C} + \text{offset} \\ \text{Amp1} &= 8.98^\circ\text{C} + 28.09^\circ\text{C} \\ \text{Amp1} &= 37.07^\circ\text{C} \end{aligned} \tag{27}$$

3. Seleccionar de la gráfica, señal de salida en lazo abierto, la primera amplitud (p1) con motivo de determinar el tiempo 1:

Para una amplitud de 37.07°C el tiempo equivale a:

$t_1 = 155.04 \text{ seg.}$

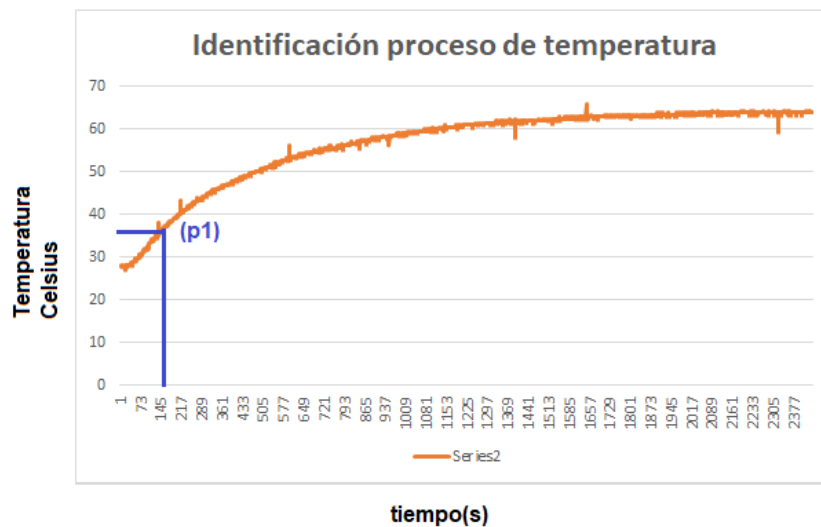


Figura 48. Selección valor %P1( $t_1$ ) con el 25% del valor de la señal de proceso (Fuente autor)

4. Determinar el %P2( $t_2$ ) con el 75% del valor de salida (según figura 46).

Regla de tres:

$$\begin{aligned} \Delta y & \text{-----} 100\% \\ \text{Amp2} & \text{-----} 75\% \\ \\ 35.94^\circ\text{C} & \text{-----} 100\% \\ \text{Amp2} & \text{-----} 75\% \end{aligned}$$

$$\begin{aligned} \text{Amp2} &= (35.92^\circ\text{C} \cdot 75) / 100 = 26.94^\circ\text{C} \\ \text{Amp2} &= 26.94^\circ\text{C} + \text{offset} \\ \text{Amp2} &= 26.94^\circ\text{C} + 28.09^\circ\text{C} \end{aligned} \tag{28}$$

Amp2= 55.03°C

5. Seleccionar de la gráfica, señal de salida en lazo abierto, la amplitud (p2) con motivo de determinar el tiempo 2:

Para una amplitud de 55.03°C el tiempo equivale a:

**t2=685.22 segundos.**




Figura 49. Selección valor %P2(t2) con el 75% del valor de la señal de proceso (Fuente autor)

6. Aplicando las ecuaciones según el método de dos puntos, podemos hallar el  $T(\tau)$  y tiempo muerto:

**Tiempo1= 155.04seg**

**Tiempo2= 685.22seg**

Reemplazado en la formula tenemos que:

$$T = (-0.91 * 155.04) + (0.91 * 685.22) \quad (29)$$

$$T = (-141.08 + 623.55)s$$

$$T = 428.47s$$

$$t_m = (1.262 * 155.04) + (-0.262 * 685.22) \quad (30)$$

$$t_m = (195.66 - 179.52)s$$

$$t_m = 16.14s$$

La función de transferencia en lazo abierto queda determinada por:

$$G(s) = \frac{K_p * e^{-t_m * s}}{Ts + 1} \quad (31)$$

Reemplazando:

$$G_p(s) = \frac{4.03 * e^{-16.14s}}{482.47s + 1} \quad \text{Método Alfaro} \quad (32)$$

La figura 50, contiene diagrama de bloque de la función de transferencia, asociada al sistema de control de temperatura de la cámara de concentración de volátiles. Se utiliza el software Matlab- Librería Simulink para realizar la simulación del sistema de temperatura.




Figura 50. Función de transferencia en lazo abierto de la cámara de concentración por el método de Alfaro.

La figura 51, ilustra diagrama de bloque de la función de transferencia en lazo abierto más tiempo muerto, asociada al sistema de control de temperatura de la cámara de concentración de gases. Se adiciona el nivel de offset que corresponde a la temperatura ambiente.




Figura 51. Sistema de control en lazo abierto por método de Alfaro.

La figura 52, ilustra diagrama de bloques del sistema de temperatura asociado a la cámara de concentración de volátiles, se procede a ingresar el tiempo muerto 16.14 segundos mediante el uso del software Matlab-Simulink.

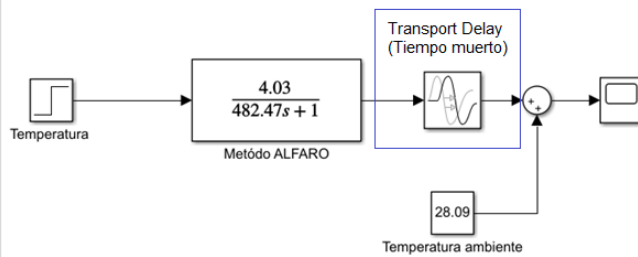
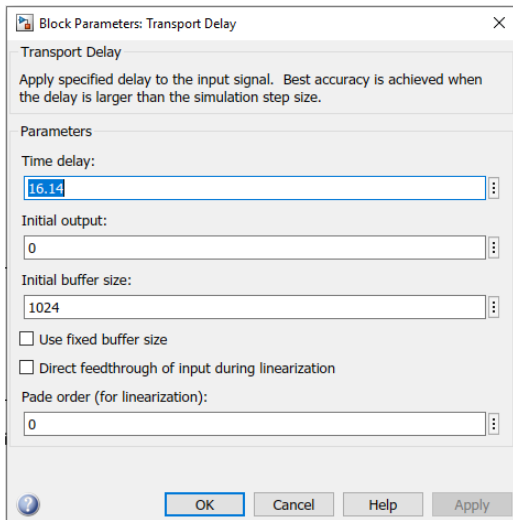


Figura 52. Configuración del tiempo muerto utilizando el software Matlab-librería Simulink.

La figura 53, representa la respuesta del sistema ante una entrada escalón en lazo abierto utilizando el método de Alfaro, la escala de tiempo se presenta en minutos. Se observa que el valor de temperatura en estado estable es aproximadamente 64 grados Celsius, comparado con el valor de respuesta real según figura 47, los datos son similares.

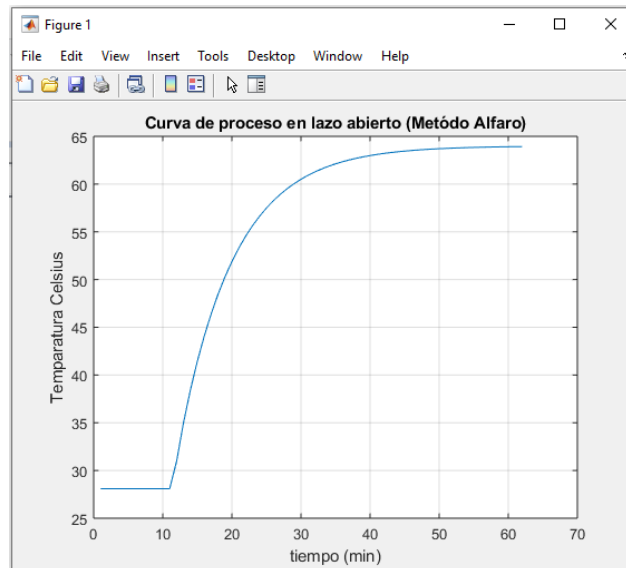


Figura 53. Simulación en Matlab de la curva de proceso en lazo abierto por el método de Alfaro.

#### 4.4.2 Sintonización controlador Proporcional-Integral PI.

La figura 54, representa el diagrama de bloques en lazo cerrado de un controlador Proporcional-Integral PI, asociado a una función de transferencia de primer orden más tiempo muerto.




Figura 54. Sistema de control acción Proporcional-Integral (PI) (Odwyen, 2009).

La tabla 5, documenta las reglas de sintonización por el método de Callender y Ziegler and Nichols.

Rule	$K_c$	$T_i$	Comment
<b>Process reaction</b>			
Callender <i>et al.</i> (1935/6). <i>Model: Method 1</i>	<sup>1</sup> $0.568/K_m \tau_m$	$3.64 \tau_m$	$\frac{\tau_m}{T_m} = 0.3$
	<sup>2</sup> $0.690/K_m \tau_m$	$2.45 \tau_m$	
Ziegler and Nichols (1942). <i>Model: Method 2</i>	$\frac{0.9 T_m}{K_m \tau_m}$	$3.33 \tau_m$	Quarter decay ratio; $\tau_m/T_m \leq 1$ .

Tabla 5. Contantes de sintonización PI, método Ziegler and Nichols (Odwyen, 2009)

Implementando la sintonización por método de Ziegler and Nichols, se obtienen los siguientes cálculos:

$$K_C = \frac{0.9 * T}{K_m * t_m} = \frac{0.9 * (482.47)}{4.03 * 16.14} = \frac{434.223}{65.0442} = 6.67 \quad (33)$$

$$T_i = 3.33 * 16.14 = 53.74s = 0.89min \quad (34)$$

#### 4.4.3 Sintonización lazo de control PI, por método Ziegler and Nichols

La figura 55, relaciona el diagrama de bloques del sistema de temperatura en lazo cerrado implementado un controlador Proporcional-Integral PI, se incluye tiempo muerto y nivel offset que relaciona la temperatura ambiente.



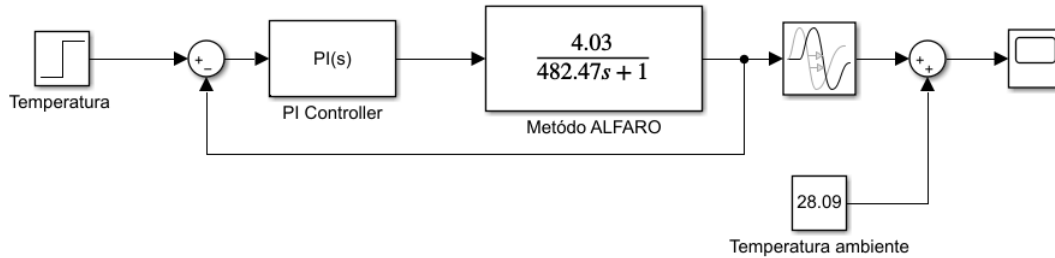


Figura 55. Diagrama de bloques del sistema de control en lazo cerrado implementando un controlador PI.

La figura 55, evidencia la respuesta simulada en simulink, del sistema de control de temperatura, con controlador Proporcional-Integral PI asociado a la cámara de concentración de gases.

#### 4.4.4 Constantes de sintonización PI

El valor de la constante integral es

$$k_i = \frac{1}{T_i} = \frac{1}{53.74} = 0.18s^{-1} \quad (35)$$

El valor de la constante proporcional se mantiene 6.67

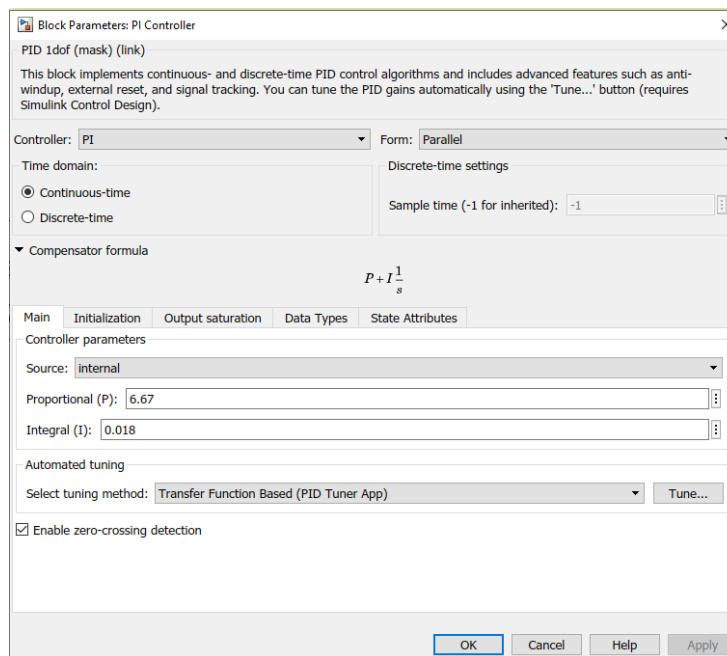


Figura 56. Bloque de parámetros en Simulink para el ingreso de constantes PI.

La figura 57, evidencia la respuesta simulada en simulink, del sistema de control de temperatura, implementando un controlador Proporcional-Integral PI asociado a la cámara de concentración de gases.




Figura 57. Respuesta del sistema con controlador PI implementando método de Ziegler and Nichols.

La figura 58, evidencia la respuesta real del sistema de control de temperatura, implementando un controlador Proporcional-Integral PI asociado a la cámara de concentración de gases, utilizando método de Ziegler and Nichols, se observa que el valor en estado estable es aproximadamente 36 grados celsius, similar al valor simulado.




Figura 58. Respuesta del sistema de control de temperatura PI método Ziegler and Nichols (Fuente autor)

#### 4.4.5 Sintonización controlador ideal Proporcional-Integral-Derivativo.

Se procede a implementar sintonización PID, para controlar la temperatura de la cámara de concentración de gases, por el método de CHIEN.

La figura 59, ilustra diagrama de bloques en lazo cerrado, implementando un controlador PID mas tiempo muerto.




Figura 59. Sistema de control acción Proporcional-Integral-Derivativo (PID)(Odwyen, 2009)

La tabla 6, relaciona las reglas por método de calender, Ziegler Nichols y Chien, para calcular las constantes de sintonización del controlador PID.

Table 10: PID controller tuning rules – FOLPD model  $G_m(s) = \frac{K_m e^{-s\tau_m}}{1 + sT_m}$

Rule	$K_c$	$T_i$	$T_d$	Comment
<b>Process reaction</b>				
Callender <i>et al.</i> (1935/6). <i>Model: Method 1</i>	$\frac{1.066}{K_m \tau_m}$	$1.418 \tau_m$	$0.353 \tau_m$ or $0.47 \tau_m$	$\frac{\tau_m}{T_m} = 0.3$
Ziegler and Nichols (1942). <i>Model: Method 2</i>	$\frac{x_1 T_m}{K_m \tau_m}$	$2 \tau_m$	$0.5 \tau_m$	$1.2 \leq x_1 \leq 2$ ; quarter decay ratio.
Chien <i>et al.</i> (1952) – regulator. <i>Model: Method 2</i>	$\frac{0.95 T_m}{K_m \tau_m}$	$2.38 \tau_m$	$0.42 \tau_m$	0% overshoot; $0.1 < \tau_m / T_m < 1$ .
	$\frac{1.2 T_m}{K_m \tau_m}$	$2 \tau_m$	$0.42 \tau_m$	20% overshoot; $0.1 < \tau_m / T_m < 1$ .

Tabla 6. Contantes de sintonización PID, métodos Ziegler and Nichols, CHIEN (Odwyen, 2009)

$$K_c = \frac{0.95 * T}{K_m * t_m} = \frac{0.95 * (482.47)}{4.03 * 16.14} = \frac{458.34}{65.04} = 7.07 \quad (36)$$

$$T_i = 2.38 * 16.14 = 38.41s = 0.64min \quad (37)$$

$$T_d = 0.42 * 16.14 = 6.77s = 0.11min \quad (38)$$

La figura 60, relaciona diagrama de bloques del sistema de temperatura en lazo cerrado, implementado un controlador Proporcional-Integral-Derivativo PID, se incluye tiempo muerto y nivel offset que relaciona la temperatura ambiente.




Figura 60. Diagrama de bloques del sistema de control en lazo cerrado implementando un PID.

#### 4.4.6 Contantes de sintonización PID

Valor de la constante proporcional se mantiene 7.07 (39)

Valor de la constante integral es  $k_i = \frac{1}{T_i} = \frac{1}{38.41} = 0.26s^{-1}$  (40)

Valor de la constante derivativa es  $k_d = 6.77s$  (41)

La figura 61, evidencia la respuesta simulada en simulink, del sistema de control de temperatura, implementando un controlador Proporcional-Integral-Derivativo PID asociado a la cámara de concentración de gases. Se evidencia estabilidad del sistema y respuesta un poco mas rapida en comparacion con el controlador PID, para la implementacion del control de temperatura del sistema CANOSE, se trabajara con el presente controlador.

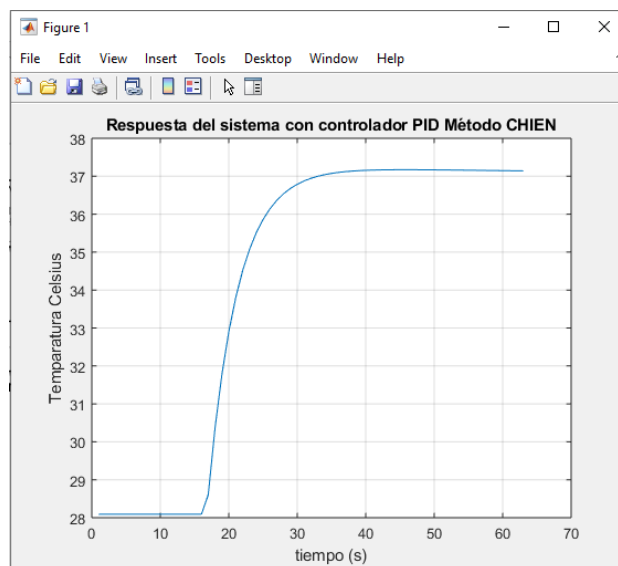


Figura 61. Respuesta del sistema con controlador PID implementando el Método CHIEN.

La figura 62, evidencia la respuesta real del sistema de control de temperatura, implementando un controlador Proporcional-Integral-Derivativo PID asociado a la cámara de concentración de gases, utilizando método de CHIEN, se observa que el valor en estado estable es aproximadamente 36 grados celsius, similar al valor simulado.




Figura 62. Controlador PID método CHIEN (Fuente autor)

#### 4.5 Sistema autónomo para la adquisición de datos en tiempo real

En la figura 63, se muestra el equipo CANOSE a modo general con cada una de las partes que lo conforman, para iniciar el proceso de medida y adquisición de datos de las muestras de cacao para el análisis, se analizaran los volátiles emitidos en masa de cacao en la fase de fermentado con 72 horas, fermentado deseado 144horas, infectado con monilia y finalmente sobrefermentado.

El peso seleccionado por cada muestra de masa de cacao, en cada fase es de 20 gramos, este valor fue definido de acuerdo a una serie de medidas realizadas, donde se inició con la selección de 100 gramos, 50 gramos y finalmente 20 gramos, los resultados se reflejan en cambios mínimos de amplitud de señal al momento de la adquisición de datos, la señal conserva su comportamiento, de esta forma se minimiza la pérdida de muestras por cada toma. En total son 5 tomas de muestras que se analizan en cada una de las fases o etapas fermentado con 72 horas, fermentado deseado 144horas, infectado con monilia y finalmente sobrefermentado.



Figura 63. Vista general nariz electrónica CANOSE (Fuente autor).

La figura 64, ilustra la cámara de concentración de volátiles (recipiente hermético amarillo) lista para ingresar los 20 gramos de masa de cacao, para el respectivo análisis.



Figura 64. Cámara de concentración de volátiles abierta (Fuente autor).

En la figura 65, se observa muestra de masa de cacao, sometida para el análisis, en este caso la cámara cuenta con sello hermético garantizando generar un espacio de cabeza del volátil, en la etapa de adquisición los volátiles circulan en lazo cerrado por medio de la activación de una bomba, la cámara de medida (matriz de sensores MQ) se encarga de percibir las concentraciones que serán enviadas en variación de voltaje por medio de una tarjeta de adquisición al PC.



Figura 65. Cámara de concentración de muestras cerrada (Fuente autor).

En la figura 66, se aprecia la huella olfativa generada por la muestra de cacao sometida para el análisis. Es importante ingresar las constantes de tiempo definidas al controlador PID para garantizar una temperatura al interior de la cámara de 33 grados Celsius. Observe el estado de las válvulas y bomba, a medida que se ejecuta el software automáticamente se realiza la conmutación de los actuadores, garantizando la adquisición de señal.

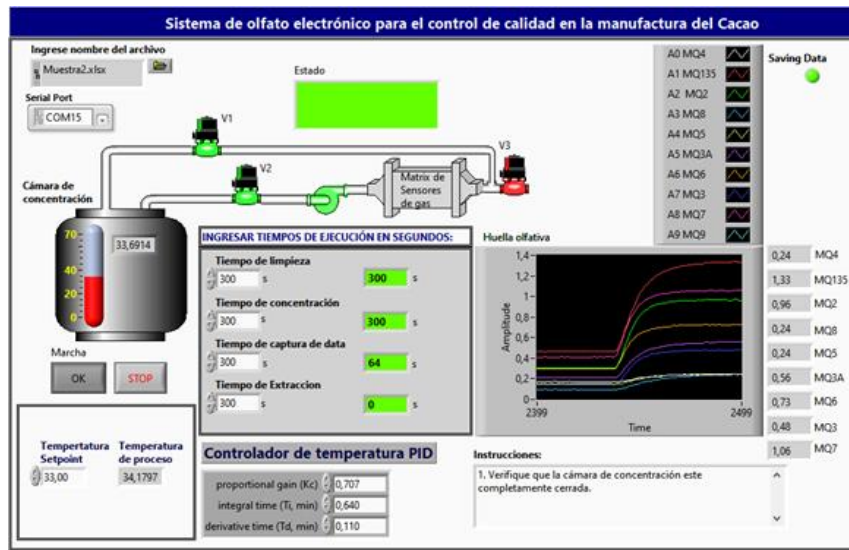


Figura 66. Ejecución del software en el proceso de adquisición de datos (Fuente autor).

#### 4.6 Selección de muestras para el análisis de volátiles

En la presente fase se procede a seleccionar las muestras del material de investigación, en este caso CLON ICS-95.

En la presente sección se relaciona el procedimiento para la medida, en cada fase, fermentado con 72 horas, fermentado deseado 144 horas, infectado con monilia y finalmente sobrefermentado. Posterior se procede a graficar la data por cada muestra de masa de cacao analizada.

#### Protocolo de muestreo:

1. Seleccionar 20 gramos por cada muestra de masa de cacao a analizar.  
Se utiliza un recipiente donde serán alojadas las muestras para proceder a pesar el material de estudio.  
El recipiente tiene un peso de 111.1 gramos, por tanto las medidas oscilan entre 130 gramos y 131 gramos  
Instrumento de medida, balanza digital.

##### 4.6.1 Masa de cacao fermentado 72 horas

La figura 67, ilustra las muestras de masa de cacao con 72 horas de fermentación, sometidas para el análisis de volátiles.



Figura 67. Muestras seleccionadas cacao con 72horas de fermentado, clon ICS-95 (Fuente autor).

Fermentado 72h	Peso gramos
M1 Muestra1	130,7
M1 Muestra2	130,6
M1 Muestra3	131,2
M1 Muestra4	131,3
M1 Muestra5	131,8
Total	655,6
Promedio	131,12
Peso recipiente	111,2
Peso promedio por muestra	19,92

Tabla 7.Promedio peso de muestra de masa de cacao con 72horas de fermentación.

#### 4.6.2 Masa de cacao deseado con 144 horas



La figura 68, ilustra las muestras de masa de cacao deseado con 144 horas de fermentación, sometidas para el análisis de volátiles.



Figura 68. Muestras seleccionadas para una fermentación de 144 horas clon ICS-95 cacao (Fuente autor).

<b>Fermentado 144h</b>	<b>Peso gramos</b>
M1 Muestra1	131,6
M1 Muestra2	130,3
M1 Muestra3	131
M1 Muestra4	131,6
M1 Muestra5	131,9
Total	656,4
Promedio	131,28
Peso recipiente	111,2
Peso promedio por muestra	20,08

Tabla 8. Promedio peso de muestra de masa de cacao con 144 horas de fermentación (Fuente autor).

### 4.6.3 Masa de cacao fermentado 144horas con monilia

La figura 69, ilustra las muestras de masa de cacao fermentado, 144horas clon ICS-95 cacao enfermo con monilia, sometidas para el análisis de volátiles.



Figura 69. Fermentación de 144horas clon ICS-95 cacao enfermo con monilia (Fuente autor).

<b>Fermentado 144h Monilia</b>	<b>Peso gramos</b>
M1 Muestra1	131,9
M1 Muestra2	131,3
M1 Muestra3	130,9
M1 Muestra4	131,9
M1 Muestra5	132
Total	658
Promedio	131,6
Peso recipiente	111,2
Peso promedio por muestra	20,4

Tabla 9.Promedio peso de muestra de masa de cacao infectado con monilia 144 horas de fermentación (Fuente autor).

### 4.6.4 Masa de cacao sobrefermentado

La figura 70, ilustra las muestras de masa de cacao sobrefermentado, sometidas para el análisis de volátiles.




Figura 70. Muestras seleccionadas cacao sobrefermentado, clon ICS-95.

<b>Sobre fermentado 288h</b>	<b>Peso gramos</b>
M1 Muestra1	131,5
M1 Muestra2	131,2
M1 Muestra3	131,1
M1 Muestra4	130,9
M1 Muestra5	130,7
Total	655,4
Promedio	131,08
Peso recipiente	111,2
Peso promedio por muestra	19,88

Tabla 10. Promedio peso de muestra de masa de cacao sobrefermentado (Fuente autor).

La figura 71, ilustra volátiles adquiridos por la nariz electrónica CANOSE en cada muestra, por ejemplo, fermentado M1-72h, corresponde a la muestra 1 analizada durante el proceso de fermentación a 72 horas. En esta etapa se seleccionan 5 muestras, cada una con un peso de 20 gramos.

#### 4.7 Concentración de volátiles emitidos durante análisis de muestras de masa de cacao fermentado por 72 horas.

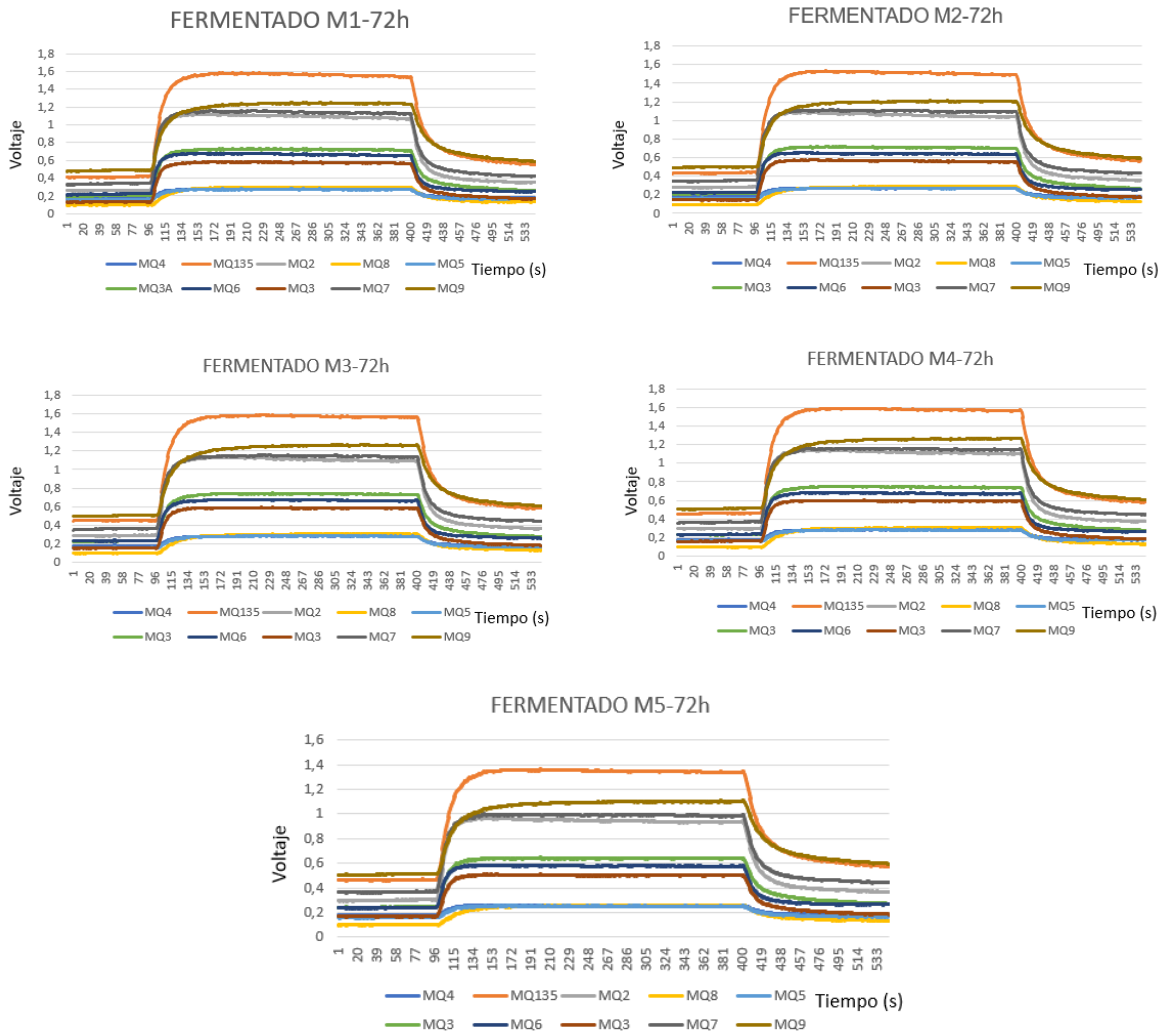


Figura 71. Volátiles adquiridos por la nariz electrónica CANOSE con un tiempo de fermentación de 72 horas (Fuente autor).

La figura 72, ilustra volátiles adquiridos por la nariz electrónica CANOSE en cada muestra, por ejemplo, fermentado M1-144h, corresponde a la muestra 1 analizada durante el proceso de fermentación a 144 horas. En esta etapa se seleccionan 5 muestras, cada una con un peso de 20 gramos.

#### 4.8 Concentración de volátiles emitidos durante análisis de muestras de masa de cacao fermentado por 144 horas.

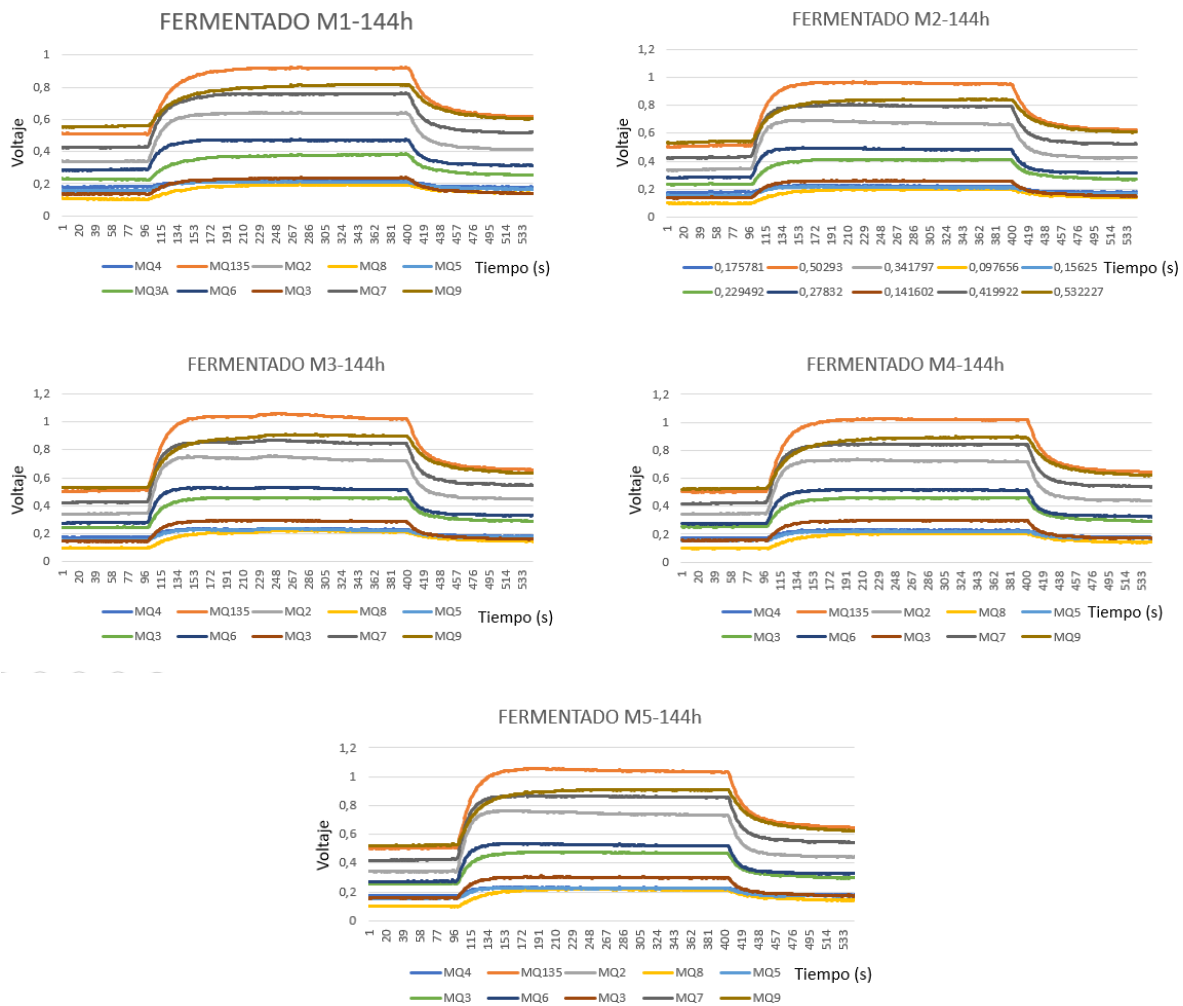


Figura 72. Volátiles adquiridos por la nariz electrónica CANOSE con un tiempo de fermentación de 144 horas (Fuente autor).

La figura 73, ilustra volátiles adquiridos por la nariz electrónica CANOSE en cada muestra, por ejemplo, Mala fermentación M1-Monilia, corresponde a la muestra 1 analizada durante el proceso de fermentación a 144 horas. En esta etapa se seleccionan 5 muestras, cada una con un peso de 20 gramos.

#### 4.9 Concentración de volátiles emitidos durante análisis de muestras de masa de cacao fermentado infectado con monilia por 144 horas.

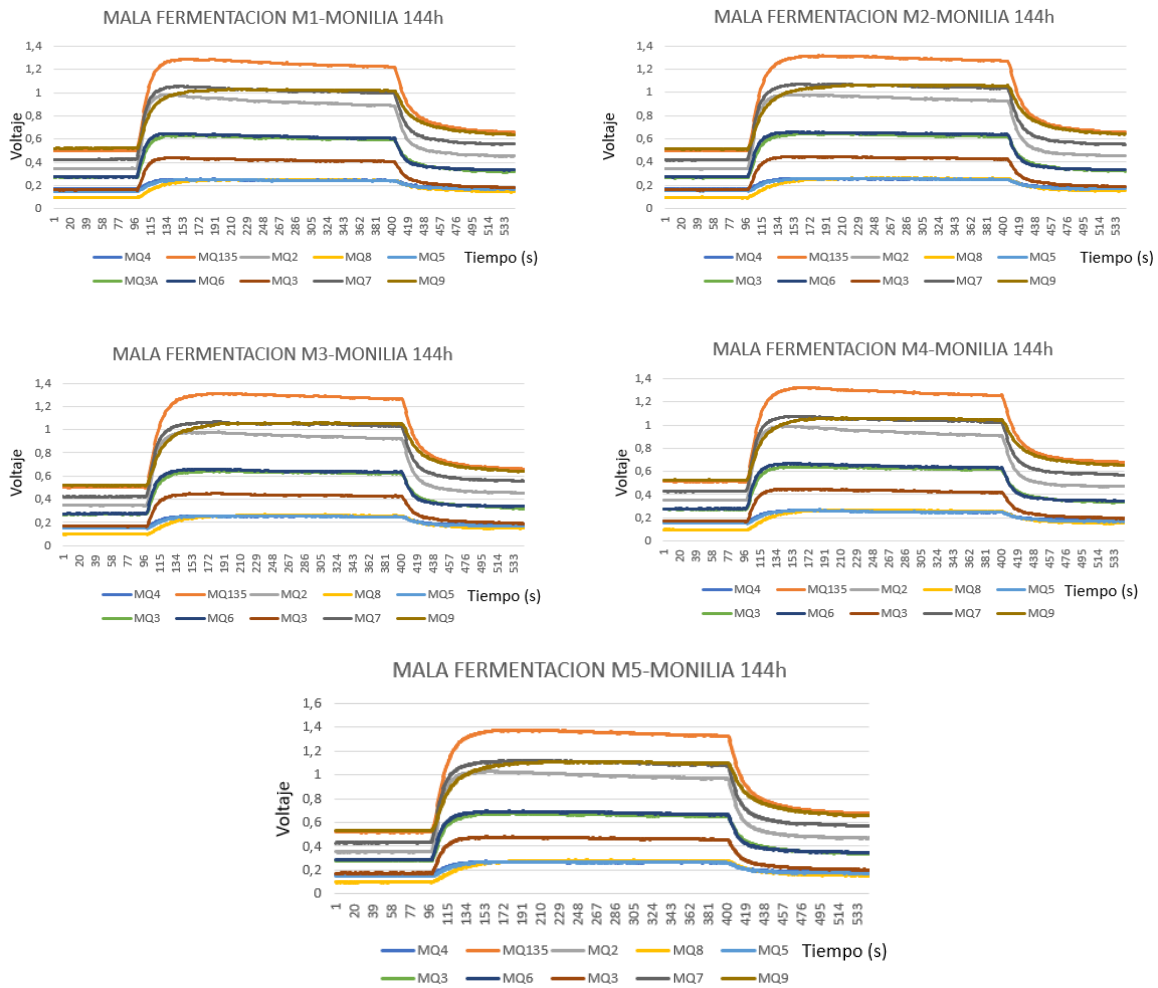


Figura 73. Volátiles adquiridos por la nariz electrónica CANOSE con un tiempo de fermentación de 144 horas infectado con monilia (Fuente autor).

La figura 74, ilustra volátiles adquiridos por la nariz electrónica CANOSE en cada muestra, por ejemplo, sobrefermentado M1, corresponde a la muestra 1 analizada durante el proceso de fermentación por periodo prolongado. En esta etapa se seleccionan 5 muestras, cada una con un peso de 20 gramos.

#### 4.10 Concentración de volátiles emitidos durante análisis de muestras de masa de cacao sobrefermentado.

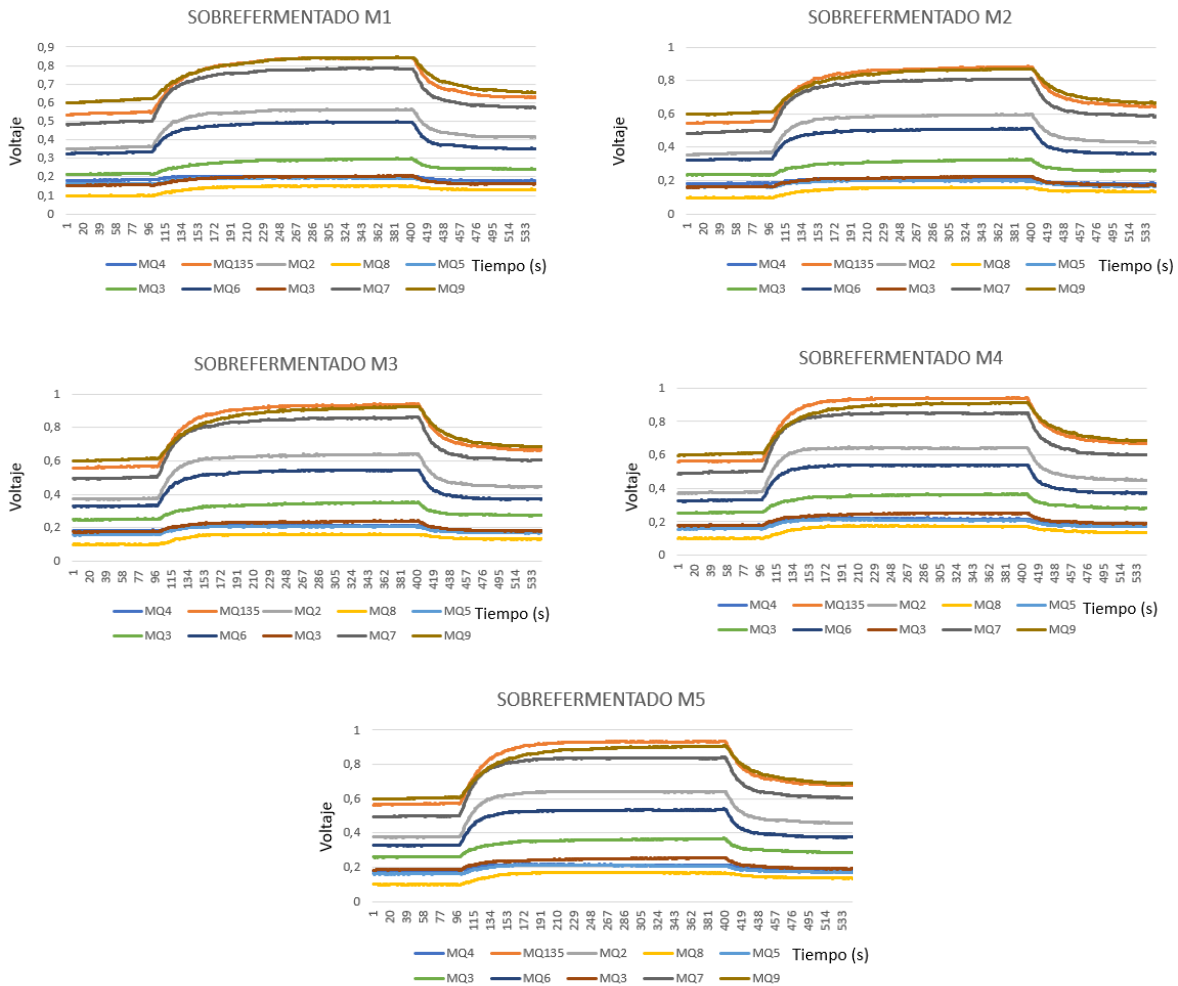


Figura 74. Volátiles adquiridos por la nariz electrónica CANOSE aplicado a muestras de cacao sobrefermentado (Fuente autor).

#### 4.11 Operación con acceso remoto

Para ejecutar la opción de supervisión remota, el software dispone de herramientas que permiten, cargar un servidor web mediante visualización por página html, para este proceso debe existir una VPN, que integre la red de la institución entre los puntos distantes, en la figura 74 se puede observar la inicialización del servidor web y la figura 75, ilustra el acceso remoto mediante internet Explorer.

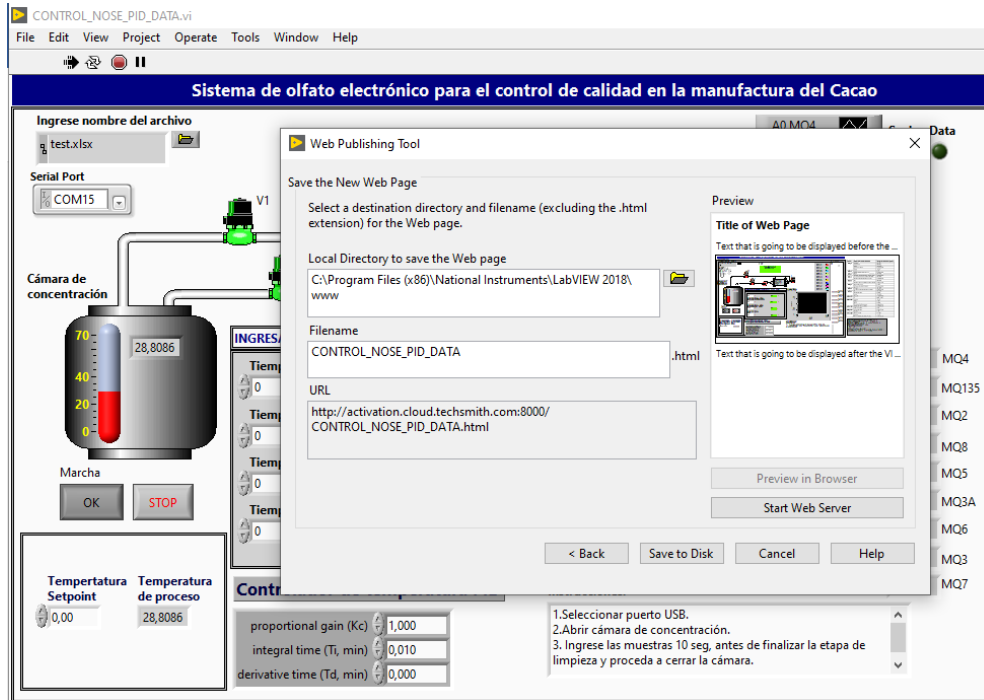


Figura 75. Iniciando el servidor web para supervisión remota (Fuente autor).

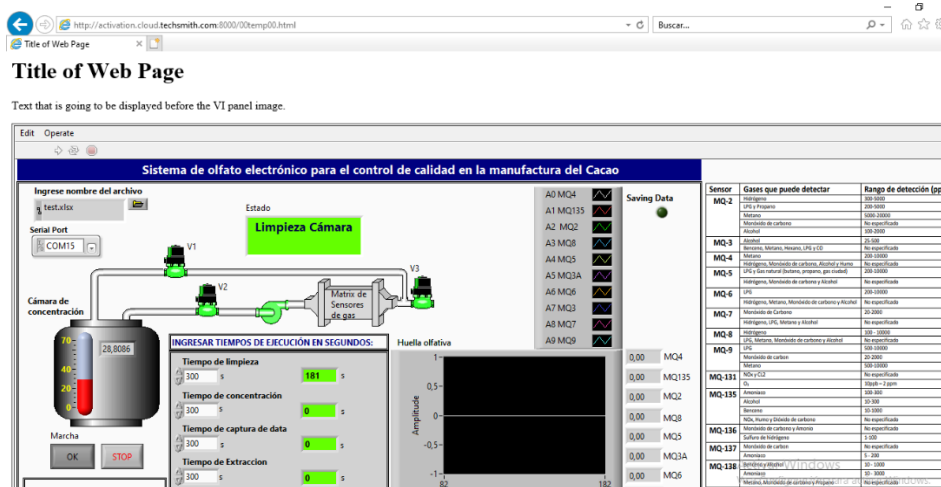


Figura 76. Supervisión remota mediante navegador internet Explorer (Fuente autor).

La dirección de acceso remoto por html es la siguiente:

<http://activation.cloud.techsmith.com:8000/00temp00.html>



## 5 PROCESAMIENTO DE DATOS ANALISIS DE RESULTADOS

Adquirida la data se procede a implementar técnicas de reconocimiento de patrones e inteligencia artificial, agrupar y clasificar cada clase, en el proceso de fermentado de cacao.

Como clases se identifican las siguientes: fermentado con 72 horas, fermentado deseado 144 horas, infectado con monilia y finalmente sobrefermentado.

La herramienta para el preprocesamiento y procesado de datos que se implementó fue Python versión 3.7.3 64-bit | Qt 5.9.6 | PyQt5 5.9.2 | Windows 10, junto con el tol kit de Anaconda y editor de consola Spyder 3.3.6.

Las técnicas en las que se implementó Python para análisis de resultados fueron, análisis de componentes principales PCA, comparando resultados con dos tipos de preprocesado de datos, escalador estándar y Manhattan. Otros métodos de clasificación basado en redes neuronales y máquinas de soporte vectorial SVM.

Otras técnicas de procesamiento de datos fueron desarrolladas con la implementación del software MATLAB, realizando el procesamiento de datos mediante análisis de clúster y DFA análisis de función discriminante.

La figura 77. se ilustra la trazabilidad de cada una de las fases aplicadas desde el proceso de selección de muestras hasta la identificación y clasificación resultado de la investigación.

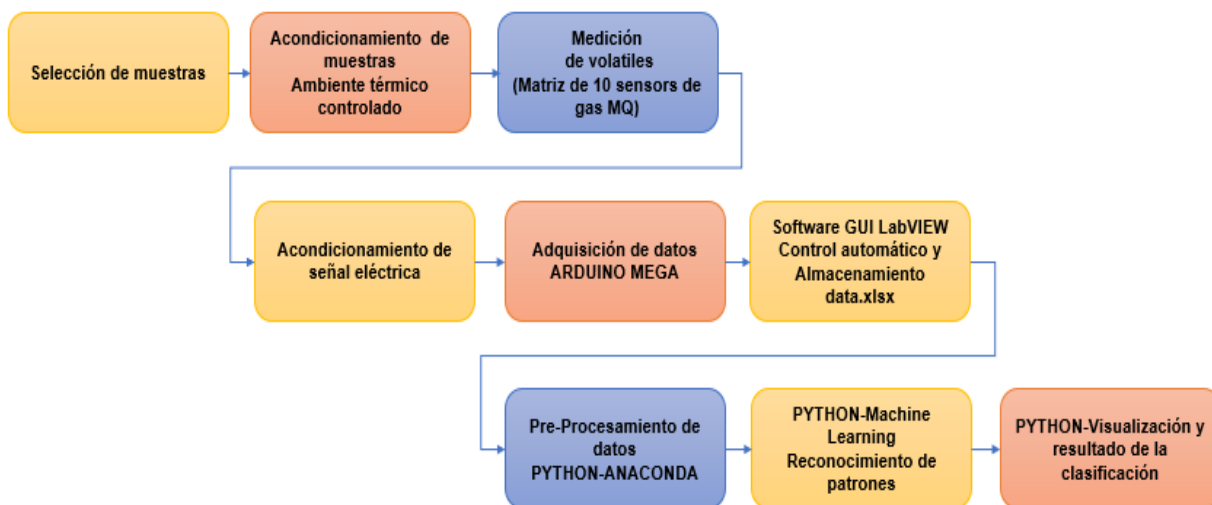


Figura 77. Diagrama de bloques general para el análisis de volátiles en el proceso de cacao fermentado (Fuente autor).

## 5.1 Análisis de componentes principales PCA

Antes de iniciar con la etapa de preprocesamiento es necesario realizar extracción de parámetros, en este caso se implementa la siguiente ecuación:

$$(G_f - G_i)$$

Ecuación 1

Gf=Ganancia final

Gi=Ganancia inicial

### 5.1.1 Preprocesado de datos StandarScaler

A continuación, se inicia con el preprocesado de datos, implementando el método StandarScaler o escalador estándar. En la figura 78, se observa la matriz de datos escalada.

MQ4	MQ135	MQ2	MQ8	MQ5	MQ3A	MQ6	MQ3	MQ7	MQ9
-1.13086	-0.98422	-1.01617	-0.887686	-1.13651	-0.891601	-1.32532	-0.898152	-1.22603	-1.29398
-0.612914	-0.811853	-0.787815	-0.69575	-0.769879	-0.730953	-1.06495	-0.756433	-0.968223	-1.03139
-0.267596	-0.501593	-0.513792	-0.215928	-0.219965	-0.53818	-0.648335	-0.579283	-0.595827	-0.59374
-0.612914	-0.605014	-0.605131	-0.503813	-0.403282	-0.538173	-0.752491	-0.614707	-0.710414	-0.652095
-0.440255	-0.501593	-0.490956	-0.215909	-0.219965	-0.506042	-0.596268	-0.543852	-0.567186	-0.564563
0.595627	0.308536	0.513788	0.263893	0.513265	0.425719	0.601477	0.37733	0.492702	0.164846
0.768286	0.429194	0.536624	0.647766	0.696582	0.554237	0.7577	0.412761	0.635935	0.39826
0.595627	0.41196	0.536624	0.647766	0.696582	0.522106	0.705633	0.37733	0.607289	0.369082
0.940945	0.41196	0.536629	0.647766	1.2465	0.489982	0.7577	0.37733	0.578642	0.310727
0.940945	0.446435	0.582301	0.743714	0.879899	0.554237	0.809777	0.448193	0.607289	0.369082
-1.47617	-1.0704	-1.13034	-1.36749	-1.50315	-1.2129	-0.908724	-1.14616	-0.996869	-0.885503
-0.958232	-1.0704	-1.08467	-0.983635	-0.953195	-1.14864	-1.01288	-1.14616	-1.02551	-0.914681
-1.13086	-1.10488	-1.17601	-1.36749	-1.31983	-1.2129	-1.01288	-1.14616	-0.968223	-0.856326
-1.30351	-1.13935	-1.19885	-1.36749	-1.31983	-1.18077	-1.01287	-1.0753	-1.08281	-0.943853
-1.30351	-1.2083	-1.26735	-1.36749	-1.31983	-1.24503	-1.1691	-1.14616	-1.19739	-1.08973
1.28626	1.72196	1.58704	1.41547	1.42981	1.5824	1.53883	1.65281	1.60989	1.74037
0.940945	1.42893	1.33586	1.12759	0.879861	1.35748	1.17431	1.44024	1.29478	1.41943
1.45892	1.58406	1.45003	1.51144	0.879861	1.48601	1.38261	1.54652	1.52395	1.68202
1.45892	1.54959	1.4957	1.51144	1.42981	1.48601	1.43469	1.58196	1.4953	1.68202
0.250345	0.704986	0.696472	0.455829	0.513265	0.747017	0.341088	0.837917	0.492708	0.690023

Figura 78. Matriz de datos preprocesado StandarScaler (Fuente autor).

La figura 79, ilustra reprocesado de datos con escalador estándar, se puede observar como el algoritmo centraliza y escala los datos, para acondicionarlos a la fase de procesamiento de datos.




Figura 79. Preprocesado de datos StandarScaler en Python (Fuente autor).

La figura 80, ilustra las clases asociadas al proceso de fermentación de cacao, proyectando los datos en una dimensión, se puede observar solapamiento entre las muestras fermentado a 72 horas junto con muestras infectadas con monilia y las muestras sobrefermentado se solapan con las muestras de fermentado a 144 h.




Figura 80. Distribución de muestras mediante análisis de componentes principales con preprocesado StandarScaler  $PC1=0.975767$  (Fuente autor).

Ahora procedemos a proyectar la distribución de las muestras en el hiperplano con 2 dimensiones.

La figura 81, ilustra los clúster asociados al proceso de fermentación de cacao. Se identifica que muestras asociadas a las clases fermentado 144h y sobrefermentado están solapadas.

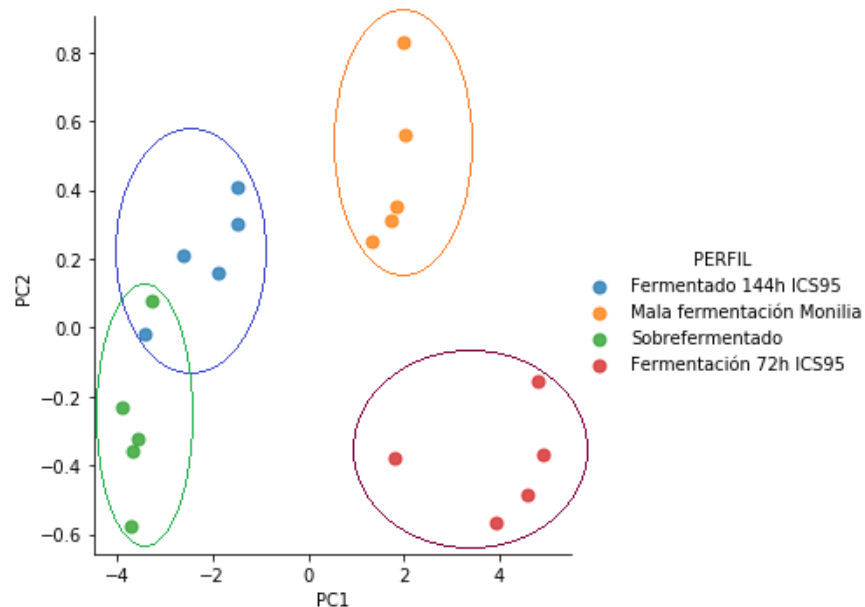


Figura 81. Clústeres asociados al proceso de fermentación de cacao mediante el uso de análisis de componentes principales preprocesado StandarScaler PC1=0.975767 y PC2=0.0154888 (Fuente autor).

### 5.1.2 Preprocesado de datos Manhattan

Se procede a implementar algoritmo en Python, con preprocesado de datos Manhattan, con el objetivo de validar si es posible mitigar solapamiento entre clases.

En la figura 82, se observa la matriz de datos escalada.

MQ4	MQ135	MQ2	MQ8	MQ5	MQ3A	MQ6	MQ3	MQ7	MQ9
0.0220052	0.210269	0.154034	0.0464545	0.02934	0.0806847	0.0977997	0.0537898	0.171149	0.134474
0.0256411	0.205128	0.155983	0.0448718	0.0299148	0.0811966	0.096154	0.0555555	0.168803	0.136752
0.0252255	0.205405	0.153153	0.0468468	0.0306307	0.079279	0.0954958	0.0558558	0.165766	0.142342
0.0226416	0.203773	0.15283	0.0433963	0.0301887	0.083019	0.0962266	0.056604	0.166038	0.145283
0.0232144	0.203571	0.153571	0.0464289	0.0303572	0.0803573	0.0964286	0.0571428	0.166071	0.142857
0.0235731	0.199752	0.16129	0.0384615	0.0260546	0.0918114	0.0955337	0.0719603	0.16129	0.130273
0.0237812	0.199762	0.155767	0.0416173	0.0261594	0.0927466	0.0951249	0.0701546	0.160523	0.134364
0.0227817	0.20024	0.157074	0.0419666	0.0263789	0.092326	0.0947244	0.0695443	0.160671	0.134293
0.0251196	0.199761	0.156699	0.0418662	0.0299042	0.0909091	0.0956938	0.0693779	0.159091	0.131579
0.0247934	0.199528	0.157025	0.0425029	0.0271547	0.0920896	0.0956316	0.0708383	0.158205	0.132231
0.0173699	0.200993	0.14392	0.0347398	0.0248138	0.0570721	0.119107	0.0372207	0.193548	0.171216
0.024213	0.196126	0.145279	0.0435837	0.0314772	0.0605325	0.11138	0.0363195	0.186441	0.164649
0.0223884	0.196517	0.139304	0.0348262	0.0273632	0.057214	0.114428	0.0373133	0.196517	0.174129
0.0203048	0.195431	0.139594	0.0355333	0.0279188	0.0609139	0.116751	0.0431472	0.190355	0.170051
0.0215636	0.196766	0.140162	0.0377361	0.0296496	0.0592992	0.115903	0.0404311	0.191374	0.167116
0.0201932	0.213345	0.155399	0.0377524	0.022827	0.096576	0.0834064	0.0825284	0.148376	0.139596
0.0197926	0.213007	0.156456	0.0377004	0.0216775	0.0970781	0.0829407	0.0829407	0.148916	0.139491
0.0216217	0.211712	0.154054	0.0396397	0.0207206	0.0963964	0.0828829	0.081982	0.14955	0.141441
0.0215441	0.209156	0.155296	0.0394974	0.0233393	0.0960503	0.083483	0.0825853	0.148115	0.140933
0.0194731	0.210768	0.158076	0.0378007	0.024055	0.0962199	0.0824741	0.0813286	0.148912	0.140893

Figura 82. Matriz de datos preprocesado Manhattan (Fuente autor).

La figura 83, ilustra preprocesado de datos con Manhattan, se puede observar como el algoritmo escala los datos, para acondicionarlos a la fase de procesamiento.




Figura 83. Preprocedado de datos Manhattan en Python (Fuente autor).

La figura 84, ilustra las clases asociadas al proceso de fermentación de cacao, proyectando los datos en una dimensión, se puede observar no hay problemas de solapamiento entre las clases.




Figura 84. Distribución de muestras mediante análisis de componentes principales con preprocesado Manhattan  $PC1=0.898028$  (Fuente autor).

La figura 85, ilustra los clúster asociados al proceso de fermentación de cacao. No se evidencia problemas de solapamiento entre las clases.




Figura 85. Clústeres asociados al proceso de fermentación de cacao mediante el uso de análisis de componentes principales preprocesado Manhattan PC1=0.898028 y PC2=0.0675872 (Fuente autor).

## 5.2 Análisis de clúster

El análisis de clúster es un método que permite descubrir asociaciones y estructuras en los datos que no son evidentes a priori pero que pueden ser útiles una vez que se han encontrado. Los resultados de un Análisis de Clúster pueden contribuir a la definición formal de un esquema de clasificación tal como una taxonomía para un conjunto de objetos, a sugerir modelos estadísticos para describir poblaciones, a asignar nuevos individuos a las clases para diagnóstico e identificación. El Análisis Clúster, conocido como Análisis de Conglomerados, es una técnica estadística multivariante que busca agrupar elementos (o variables) tratando de lograr la máxima homogeneidad en cada grupo y la mayor diferencia entre los grupos (F. Fuente, 2011)

La figura 86, muestra la distribución de las estructuras asociadas a cada una de las clases vinculadas al proceso de fermentación, se puede observar que la clase A fermentado 144 horas y la clase C sobrefermentado registran solapamiento.




Figura 86. Análisis de clúster en el proceso de fermentado de cacao (Fuente autor).

### 5.3 Análisis de función discriminante

El análisis discriminante es una técnica, sustancialmente, clasificatoria. A partir de una variable dependiente cualitativa y un conjunto de una o más variables independientes cuantitativas (en caso contrario habrá que recodificar los valores de las variables no cuantitativas), el análisis discriminante permite clasificar a los individuos o casos en alguno de los grupos establecidos por la variable dependiente. Las variables que se utilizan para realizar la clasificación de los individuos se denominan variables clasificadoras, También se emplean las denominaciones de variables criterio o variables predictoras, o la denominación genérica de variables explicativas. La información de las variables clasificadoras se sintetiza en unas funciones, denominadas funciones discriminantes, que son las que finalmente se utilizan en el proceso de clasificación (Crespo, 2013).

La figura 87, ilustra agrupamiento de clúster, discriminando cada una de las clases asociadas al proceso de fermentado de cacao, que corresponden a fermentado F144horas, FMonilia, Sobrefermentado, F72horas.



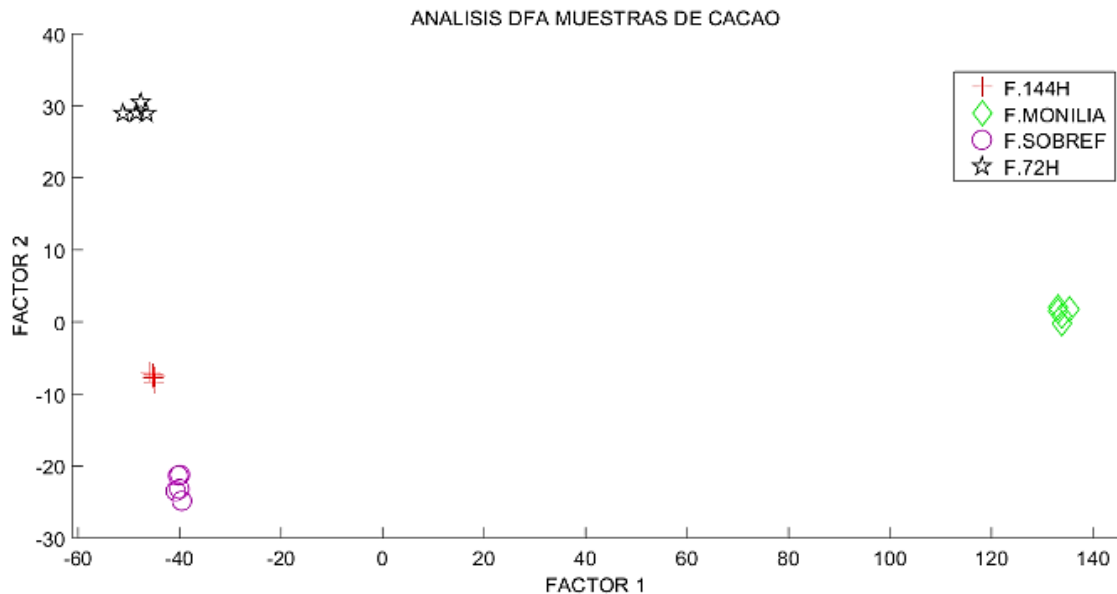


Figura 87. Análisis de función discriminante aplicado al proceso de fermentado de cacao (Fuente autor).

## 5.4 Red Neuronal perceptrón multicapa MLPC

La clase MLP Clasificadora implementa un algoritmo de perceptrón multicapa (MLP) que se entrena usando Backpropagation. MLP entrena en dos matrices: matriz X de tamaño (n\_samples, n\_features), que contiene las muestras de entrenamiento representadas como vectores de características de punto flotante; y matriz y de tamaño (n\_samples,) que contiene los valores objetivo (etiquetas de clase) para las muestras de entrenamiento (Fabisch & Passos Alexandre, 2017)

Funciones de activación en python: {'identidad', 'logística', 'tanh', 'relu'}, predeterminado 'relu'

### 5.4.1 Función de activación para la capa oculta.

- 'identidad', activación no operativa, útil para implementar un cuello de botella lineal, devuelve  $f(x) = x$
- 'logístico', la función sigmoidea logística, devuelve  $f(x) = 1 / (1 + \exp(-x))$ .
- 'tanh', la función tan hiperbólica, devuelve  $f(x) = \tanh(x)$ .
- 'relu', la función de unidad lineal rectificadora, devuelve  $f(x) = \max(0, x)$ . Para el desarrollo del algoritmo se selecciona la presente función de activación.

### 5.4.2 El solucionador para la optimización del peso.

Solucionador : {'lbfgs', 'sgd', 'adam'}, predeterminado 'adam', para el desarrollo del algoritmo se implementa lbfgs optimizador de métodos cuasi Newton

- 'lbfgs' es un optimizador en la familia de los métodos cuasi-Newton.
- 'sgd' se refiere al descenso de gradiente estocástico.
- 'adam' se refiere a un optimizador estocástico basado en gradiente propuesto por Kingma, Diederik y Jimmy Ba (Fabisch & Passos Alexandre, 2017)

El método de preprocesado de datos seleccionado es Manhattan, a continuación, se relaciona el código implementado para la red neuronal, inicialmente se selecciona para el entrenamiento 3 neuronas en la primera capa oculta, 3 neuronas en la segunda capa oculta y 3 neuronas en la tercera capa oculta, entrena con el 80% la etiqueta de datos utilizada (X\_train) para el entrenamiento y (y\_train), para la validación se realiza con el 20% de los datos, la etiqueta se denota como X\_test y Y\_test.

A continuación, las líneas de código en Python donde se realiza el entrenamiento de la red neuronal. Los caracteres X, Y, son la data que contiene la información de los objetivos: fermentado con 72 horas, fermentado deseado 144 horas, infectado con monilia y finalmente sobrefermentado, el método de preprocesamiento aplicado manhattan. El número de capas se define con la línea de código layer\_sizes=(3,3,3),

- `X_train, X_test, y_train, y_test = train_test_split(X,Y,test_size=0.2, random_state=42,stratify=Y)`
- `mlp=MLPClassifier(hidden_layer_sizes=(3,3,3), activation = 'relu', max_iter=500,alpha=0.0001,solver='lbfgs', random_state=21,tol=0.000000001)`
- `mlp.fit(X_train,y_train)# Modelo entrenado`

El siguiente código permite guardar el modelo entrenado, posteriormente se ingresan datos para validar.

- `from sklearn.externals import joblib`
- `joblib.dump(mlp,'modelo_entrenado.pkl')`
- `predictions=mlp.predict(X_test)`
- `print(classification_report(y_test,predictions))`
- `print(y_test)#objetivos`
- `print(predictions)#Salida estimada`

En la figura 88, se ilustra la matriz con preprocesado Manhattan, que será ingresada a la red neuronal para el entrenamiento.

Index	MQ4	MQ135	MQ2	MQ8	MQ5	MQ3A	MQ6	MQ3	MQ7	MQ9	PERFIL
0	0.0220052	0.210269	0.154034	0.0464545	0.02934	0.0806847	0.0977997	0.0537898	0.171149	0.134474	0
1	0.0256411	0.205128	0.155983	0.0448718	0.0299148	0.0811966	0.096154	0.0555555	0.168803	0.136752	0
2	0.0252255	0.205405	0.153153	0.0468468	0.0306307	0.079279	0.0954958	0.0558558	0.165766	0.142342	0
3	0.0226416	0.203773	0.15283	0.0433963	0.0301887	0.083019	0.0962266	0.056604	0.166038	0.145283	0
4	0.0232144	0.203571	0.153571	0.0464289	0.0303572	0.0803573	0.0964286	0.0571428	0.166071	0.142857	0
5	0.0235731	0.199752	0.16129	0.0384615	0.0260546	0.0918114	0.0955337	0.0719603	0.16129	0.130273	1
6	0.0237812	0.199762	0.155767	0.0416173	0.0261594	0.0927466	0.0951249	0.0701546	0.160523	0.134364	1
7	0.0227817	0.20024	0.157074	0.0419666	0.0263789	0.092326	0.0947244	0.0695443	0.160671	0.134293	1
8	0.0251196	0.199761	0.156699	0.0418662	0.0299042	0.0909091	0.0956938	0.0693779	0.159091	0.131579	1
9	0.0247934	0.199528	0.157025	0.0425029	0.0271547	0.0920896	0.0956316	0.0708383	0.158205	0.132231	1
10	0.0173699	0.200993	0.14392	0.0347398	0.0248138	0.0570721	0.119107	0.0372207	0.193548	0.171216	2
11	0.024213	0.196126	0.145279	0.0435837	0.0314772	0.0605325	0.11138	0.0363195	0.186441	0.164649	2
12	0.0223884	0.196517	0.139304	0.0348262	0.0273632	0.057214	0.114428	0.0373133	0.196517	0.174129	2
13	0.0203048	0.195431	0.139594	0.0355333	0.0279188	0.0609139	0.116751	0.0431472	0.190355	0.170051	2
14	0.0215636	0.196766	0.140162	0.0377361	0.0296496	0.0592992	0.115903	0.0404311	0.191374	0.167116	2
15	0.0201932	0.213345	0.155399	0.0377524	0.022827	0.096576	0.0834064	0.0825284	0.148376	0.139596	3
16	0.0197926	0.213007	0.156456	0.0377004	0.0216775	0.0970781	0.0829407	0.0829407	0.148916	0.139491	3
17	0.0216217	0.211712	0.154054	0.0396397	0.0207206	0.0963964	0.0828829	0.081982	0.14955	0.141441	3
18	0.0215441	0.209156	0.155296	0.0394974	0.0233393	0.0960503	0.083483	0.0825853	0.148115	0.140933	3
19	0.0194731	0.210768	0.158076	0.0378007	0.024055	0.0962199	0.0824741	0.0813286	0.148912	0.140893	3

Figura 88. Matriz con preprocesado de datos Manhattan para entrenamiento de la red neuronal (Fuente autor).

La columna denominada perfil se relacionan con los objetivos para la clasificación.

Objetivo 0: Fermentado 144h

Objetivo 1: Mala fermentación monilia

Objetivo 2: Sobrefermentado

Objetivo 3: Fermentación 72h

De la matriz de la figura 88, el algoritmo selecciona al azar el 80% de los datos para realizar el entrenamiento, en la figura se observa la matriz con los datos seleccionados X\_train que corresponde a los datos para el entrenamiento.

Index	MQ4	MQ135	MQ2	MQ8	MQ5	MQ3A	MQ6	MQ3	MQ7	MQ9
7	0.0227817	0.20024	0.157074	0.0419666	0.0263789	0.092326	0.0947244	0.0695443	0.160671	0.134293
2	0.0252255	0.205405	0.153153	0.0468468	0.0306307	0.079279	0.0954958	0.0558558	0.165766	0.142342
11	0.024213	0.196126	0.145279	0.0435837	0.0314772	0.0605325	0.11138	0.0363195	0.186441	0.164649
16	0.0197926	0.213007	0.156456	0.0377004	0.0216775	0.0970781	0.0829407	0.0829407	0.148916	0.139491
10	0.0173699	0.200993	0.14392	0.0347398	0.0248138	0.0570721	0.119107	0.0372207	0.193548	0.171216
15	0.0201932	0.213345	0.155399	0.0377524	0.022827	0.096576	0.0834064	0.0825284	0.148376	0.139596
13	0.0203048	0.195431	0.139594	0.0355333	0.0279188	0.0609139	0.116751	0.0431472	0.190355	0.170051
0	0.0220052	0.210269	0.154034	0.0464545	0.02934	0.0806847	0.0977997	0.0537898	0.171149	0.134474
1	0.0256411	0.205128	0.155983	0.0448718	0.0299148	0.0811966	0.096154	0.0555555	0.168803	0.136752
18	0.0215441	0.209156	0.155296	0.0394974	0.0233393	0.0960503	0.083483	0.0825853	0.148115	0.140933
17	0.0216217	0.211712	0.154054	0.0396397	0.0207206	0.0963964	0.0828829	0.081982	0.14955	0.141441
6	0.0237812	0.199762	0.155767	0.0416173	0.0261594	0.0927466	0.0951249	0.0701546	0.160523	0.134364
14	0.0215636	0.196766	0.140162	0.0377361	0.0296496	0.0592992	0.115903	0.0404311	0.191374	0.167116
5	0.0235731	0.199752	0.16129	0.0384615	0.0260546	0.0918114	0.0955337	0.0719603	0.16129	0.130273
4	0.0232144	0.203571	0.153571	0.0464289	0.0303572	0.0803573	0.0964286	0.0571428	0.166071	0.142857
8	0.0251196	0.199761	0.156699	0.0418662	0.0299042	0.0909091	0.0956938	0.0693779	0.159091	0.131579

Figura 89. Datos de entrenamiento (X\_train) (Fuente autor).

La figura 90, relaciona los objetivos seleccionados para el entrenamiento.

y\_train - DataFrame

Index	PERFIL
7	1
2	0
11	2
16	3
10	2
15	3
13	2
0	0
1	0
18	3
17	3
6	1
14	2
5	1
4	0
8	1

Figura 90. Objetivos seleccionados para el entrenamiento de la red neuronal (y\_train) (Fuente autor).

La figura 91, evidencia matriz de prueba que corresponde al 20% de la data.

Index	MQ4	MQ135	MQ2	MQ8	MQ5	MQ3A	MQ6	MQ3	MQ7	MQ9
9	0.0247934	0.199528	0.157025	0.0425029	0.0271547	0.0920896	0.0956316	0.0708383	0.158205	0.132231
3	0.0226416	0.203773	0.15283	0.0433963	0.0301887	0.083019	0.0962266	0.056604	0.166038	0.145283
19	0.0194731	0.210768	0.158076	0.0378007	0.024055	0.0962199	0.0824741	0.0813286	0.148912	0.140893
12	0.0223884	0.196517	0.139304	0.0348262	0.0273632	0.057214	0.114428	0.0373133	0.196517	0.174129

Figura 91. Matriz de prueba (X\_test) (Fuente autor).

La figura 92, relaciona los objetivos de prueba de la red neuronal el cual corresponde al 20% de los datos.

Index	PERFIL
9	1
3	0
19	3
12	2

Figura 92. Datos de prueba, objetivos de la red neuronal (y\_test) (Fuente autor).

A continuación en la figura 93, se observa resultado de la predicción de la red neuronal MPLC, utilizando 3 neuronas en la primera capa oculta, 3 neuronas en la segunda capa oculta, y finalmente 3 neuronas en la tercera capa oculta, los datos suministrados (X\_test), se obtiene los siguientes resultados ver tabla 11, la red predice solo el objetivo 3, con una precisión de 0.25, y una puntuación del 0.4, los demás objetivos no los clasifica.

Index	Objetivos o Perfil	Predicción
9	1	3
3	0	3
19	3	3
12	2	3

Tabla 11. Predicción red neuronal MLPC con 3,3,3, capas ocultas

```

Terminal de IPython
Terminal 1/A
y = column_or_1d(y, warn=True)
C:\Users\Alex_ing\Anaconda3\lib\site-packages\sklearn\svm\base.py:193:
FutureWarning: The default value of gamma will change from 'auto' to 'scale'
in version 0.22 to account better for unscaled features. Set gamma explicitly
to 'auto' or 'scale' to avoid this warning.
"avoid this warning.", FutureWarning)
precision    recall  f1-score   support

   0.0         0.00         0.00         0.00         1
   1.0         0.00         0.00         0.00         1
   2.0         0.00         0.00         0.00         1
   3.0         0.25         1.00         0.40         1

 accuracy          0.25         4
 macro avg         0.06         0.25         0.10         4
weighted avg         0.06         0.25         0.10         4

 PERFIL
9      1.0
3      0.0
19     3.0
12     2.0
Predicciones
[3. 3. 3. 3.]
Terminal de IPython  Historial de comandos
Fin de línea: CRLF  Codificación: UTF-8  Línea: 1213  Columna: 1  Memoria: 71 %

```

Figura 93. Predicción de resultados objetivos de la red neuronal MLPC con 3,3,3 capas ocultas en Python (Fuente autor).

Para ajustar el entrenamiento se procede a incrementar el número de capas ocultas, implementando 7 capas en la primera capa oculta, 7 capas en la segunda, y 7 capas en la tercera, en la línea de código `hidden_layer_sizes=(7,7,7)`, se define el número de capas oculta de la red neuronal MLPC.

- `X_train, X_test, y_train, y_test = train_test_split(X,Y,test_size=0.2, random_state=42,stratify=Y)`
- `mlp=MLPClassifier(hidden_layer_sizes=(7,7,7), activation = 'relu', max_iter=500,alpha=0.0001,solver='lbfgs', random_state=21,tol=0.000000001)# solver solucionador : {'lbfgs con 8,8,8 capas 100%', 'sgd', 'adam se utiliza solver'}, predeterminado 'adam'`
- `mlp.fit(X_train,y_train)`

A continuación en la figura 94 se observa resultado de la predicción de la red neuronal MPLC, los datos suministrados (`X_test`), se obtiene los siguientes resultados ver tabla 12, la red predice los objetivos 0 con una puntuación de 1.0, el objetivo 1 con puntuación de 1.0, objetivo 2 con una puntuación de 1.0 y finalmente el objetivo 3, con una puntuación de 1.0, logrando el entrenamiento.

Index	Objetivos o Perfil	Predicción
9	1	1
3	0	0
19	3	3
12	2	2

Tabla 12. Predicción red neuronal MLPC con 7,7,7, capas ocultas.

```

Terminal de IPython
Terminal 1/A
C:\Users\Alex_ing\Anaconda3\lib\site-packages\sklearn\network\_multilayer_perceptron.py:921: DataConversionWarning: A column-vector y was passed when a 1d array was expected. Please change the shape of y to (n_samples, ), for example using ravel().
y = column_or_1d(y, warn=True)
      precision    recall  f1-score   support

      0.0         1.00      1.00      1.00         1
      1.0         1.00      1.00      1.00         1
      2.0         1.00      1.00      1.00         1
      3.0         1.00      1.00      1.00         1

 accuracy          1.00      1.00      1.00         4
 macro avg          1.00      1.00      1.00         4
 weighted avg          1.00      1.00      1.00         4

 PERFIL
 9      1.0
 3      0.0
19      3.0
12      2.0

 Predicciones
 [1. 0. 3. 2.]

Terminal de IPython  Historial de comandos
Fin de línea: CRLF  Codificación: UTF-8  Línea: 1211  Columna: 1  Memoria: 73 %

```

Figura 94. Predicción de resultados objetivos de la red neuronal MLPC con 7,7,7 capas ocultas en Python (Fuente autor).

Para validar la red neuronal MLPC, se procede a adquirir nuevos datos, trabajando con el equipo CANOSE con cacao fermentado a 144 horas, el tipo de preprocesado Manhattan, finalmente se procede obtener la clasificación.

	MQ4	MQ135	MQ2	MQ8	MQ5	MQ3A	MQ6	MQ3	MQ7	MQ9
0	0,024038	0,190705	0,147436	0,044872	0,036859	0,070513	0,113782	0,064103	0,168269	0,139423
1	0,02473	0,190108	0,151468	0,043277	0,03864	0,069552	0,117465	0,06337	0,166924	0,134467
2	0,023004	0,189445	0,14885	0,041949	0,036536	0,074425	0,115021	0,066306	0,166441	0,138024
3	0,025575	0,187979	0,14578	0,043478	0,038363	0,074169	0,116368	0,063939	0,164962	0,139386
4	0,028708	0,181818	0,141148	0,052632	0,045454	0,076555	0,110048	0,059809	0,167464	0,136363
5	0,023573	0,199752	0,16129	0,038462	0,026055	0,091811	0,095534	0,07196	0,16129	0,130273
6	0,023781	0,199762	0,155767	0,041617	0,026159	0,092747	0,095125	0,070155	0,160523	0,134364
7	0,022782	0,20024	0,157074	0,041967	0,026379	0,092326	0,094724	0,069544	0,160671	0,134293
8	0,02512	0,199761	0,156699	0,041866	0,029904	0,090909	0,095694	0,069378	0,159091	0,131579
9	0,024793	0,199528	0,157025	0,042503	0,027155	0,09209	0,095632	0,070838	0,158205	0,132231
10	0,01737	0,200993	0,14392	0,03474	0,024814	0,057072	0,119107	0,037221	0,193548	0,171216
11	0,024213	0,196126	0,145279	0,043584	0,031477	0,060533	0,11138	0,03632	0,186441	0,164649
12	0,022388	0,196517	0,139304	0,034826	0,027363	0,057214	0,114428	0,037313	0,196517	0,174129
13	0,020305	0,195431	0,139594	0,035533	0,027919	0,060914	0,116751	0,043147	0,190355	0,170051
14	0,021564	0,196766	0,140162	0,037736	0,02965	0,059299	0,115903	0,040431	0,191374	0,167116
15	0,020193	0,213345	0,155399	0,037752	0,022827	0,096576	0,083406	0,082528	0,148376	0,139596
16	0,019793	0,213007	0,156456	0,0377	0,021678	0,097078	0,082941	0,082941	0,148916	0,139491
17	0,021622	0,211712	0,154054	0,03964	0,020721	0,096396	0,082883	0,081982	0,14955	0,141441
18	0,021544	0,209156	0,155296	0,039497	0,023339	0,09605	0,083483	0,082585	0,148115	0,140933
19	0,019473	0,210768	0,158076	0,037801	0,024055	0,09622	0,082474	0,081329	0,148912	0,140893

Figura 95. Matriz con muestras de cacao nuevas, fermentado 144h (Fuente autor).

	MQ4	MQ135	MQ2	MQ8	MQ5	MQ3A	MQ6	MQ3	MQ7	MQ9
0	0,022005	0,210269	0,154034	0,046455	0,02934	0,080685	0,0978	0,05379	0,171149	0,134474
1	0,025641	0,205128	0,155983	0,044872	0,029915	0,081197	0,096154	0,055555	0,168803	0,136752
2	0,025225	0,205405	0,153153	0,046847	0,030631	0,079279	0,095496	0,055856	0,165766	0,142342
3	0,022642	0,203773	0,15283	0,043396	0,030189	0,083019	0,096227	0,056604	0,166038	0,145283
4	0,023214	0,203571	0,153571	0,046429	0,030357	0,080357	0,096429	0,057143	0,166071	0,142857
5	0,023573	0,199752	0,16129	0,038462	0,026055	0,091811	0,095534	0,07196	0,16129	0,130273
6	0,023781	0,199762	0,155767	0,041617	0,026159	0,092747	0,095125	0,070155	0,160523	0,134364
7	0,022782	0,20024	0,157074	0,041967	0,026379	0,092326	0,094724	0,069544	0,160671	0,134293
8	0,02512	0,199761	0,156699	0,041866	0,029904	0,090909	0,095694	0,069378	0,159091	0,131579
9	0,024793	0,199528	0,157025	0,042503	0,027155	0,09209	0,095632	0,070838	0,158205	0,132231
10	0,01737	0,200993	0,14392	0,03474	0,024814	0,057072	0,119107	0,037221	0,193548	0,171216
11	0,024213	0,196126	0,145279	0,043584	0,031477	0,060533	0,11138	0,03632	0,186441	0,164649
12	0,022388	0,196517	0,139304	0,034826	0,027363	0,057214	0,114428	0,037313	0,196517	0,174129
13	0,020305	0,195431	0,139594	0,035533	0,027919	0,060914	0,116751	0,043147	0,190355	0,170051
14	0,021564	0,196766	0,140162	0,037736	0,02965	0,059299	0,115903	0,040431	0,191374	0,167116
15	0,020193	0,213345	0,155399	0,037752	0,022827	0,096576	0,083406	0,082528	0,148376	0,139596
16	0,019793	0,213007	0,156456	0,0377	0,021678	0,097078	0,082941	0,082941	0,148916	0,139491
17	0,021622	0,211712	0,154054	0,03964	0,020721	0,096396	0,082883	0,081982	0,14955	0,141441
18	0,021544	0,209156	0,155296	0,039497	0,023339	0,09605	0,083483	0,082585	0,148115	0,140933
19	0,019473	0,210768	0,158076	0,037801	0,024055	0,09622	0,082474	0,081329	0,148912	0,140893

Figura 96. Matriz de procesado del modelo de entrenamiento (Fuente autor).

- from sklearn.externals import joblib
- import pandas as pd # permite manipular datos matriciales
- from sklearn.metrics import classification\_report
- #datos= pd.read\_excel('preprocesado.xlsx', sheet\_name='preprocesado')
- xlsx = pd.ExcelFile('preprocesado.xlsx')
- #xlsx = pd.ExcelFile('preprocesado.xlsx')
- df1=xlsx.parse('preprocesado')# Matriz con valores entrenados
- data = df1.iloc[:,1:11] # Remember that Python does not slice inclusive of the ending index.
- train=df1.iloc[:,21:,11]

la figura 97 ilustra entrenamiento de la red neuronal con el valor de acierto. Se evidencia que las primeros 5 muestras de cacao del vector fila, están clasificadas con proceso de fermentación con 144horas.



```

In [9]: runfile('D:/2019/TESIS 30 MAYO/TESIS/phyton tesis/Nueva carpeta/ej/
comprobar2.py', wdir='D:/2019/TESIS 30 MAYO/TESIS/phyton tesis/Nueva carpeta/
ej')
1.0
[0. 0. 0. 0. 0. 1. 1. 1. 1. 1. 2. 2. 2. 2. 2. 3. 3. 3. 3. 3.]
      precision    recall  f1-score   support

     0       1.00      1.00      1.00         5
     1       1.00      1.00      1.00         5
     2       1.00      1.00      1.00         5
     3       1.00      1.00      1.00         5

 accuracy                   1.00         20
 macro avg       1.00      1.00      1.00         20
 weighted avg    1.00      1.00      1.00         20

Perfil 0=Fermentado 144h: Perfil 1=Monilia: Perfil 2=Sobrefermentado: Perfil
3=Fermentado 72h

In [10]:

```

Figura 97. Validación red neuronal MPLC (Fuente autor).

## 5.5 Máquina de soporte vectorial

A continuación, se relaciona líneas del código fuente donde se implementa el clasificador basado en máquina de soporte vectorial con Python, el preprocesado de datos se realiza con método StandardScaler, posterior se procede a iniciar con el entrenamiento y clasificación:

- ##### MSV Support Vector Machines
- Z=x\_std.astype (float)
- ##### CLASIFICADOR SVM
- X\_trainsvm, X\_testsvm, y\_traingsvm, y\_testsvm = train\_test\_split(Z,Y,test\_size=0.2, random\_state=42,stratify=Y)
- clf=SVC(kernel='poly').fit(X\_trainsvm,y\_traingsvm) # modelo entrenado linear, 'poly', 'rbf', 'sigmoid', '...
- print(clf.score(X\_testsvm,y\_testsvm))
- pred=clf.predict(X\_testsvm)

```

##### | MSV Support Vector Machines

Z=x_std.astype (float)

##### CLASIFICADOR SVM

X_trainsvm, X_testsvm, y_traingsvm, y_testsvm = train_test_split(Z,Y,test_size=0
clf=SVC(kernel='poly').fit(X_trainsvm,y_traingsvm) # modelo entrenado linear, '
print(clf.score(X_testsvm,y_testsvm))

pred=clf.predict(X_testsvm)

In [340]: print(clf.score(X_testsvm,y_testsvm))
0.5

In [341]: pred
Out[341]: array([1., 1., 1., 2.])

In [342]: y_testsvm
Out[342]:
PERFIL
9      1.0
3      0.0
19     3.0
12     2.0

```

Figura 98. Máquina de soporte vectorial Kernel poly- preprocesado StandardScaler (Fuente autor).

## Modelo entrenado:

- clf
- Out[343]:
- SVC(C=1.0, cache\_size=200, class\_weight=None, coef0=0.0,
- decision\_function\_shape='ovr', degree=3, gamma='auto\_deprecated',
- kernel='poly', max\_iter=-1, probability=False, random\_state=None,
- shrinking=True, tol=0.001, verbose=False)

El score realiza un acierto del 50% lo cual no es muy eficiente en la clasificación de datos, procedemos a cambiar la función que utilizara el algoritmo, por el kernel 'rbf'

```
#### red neuronal
X_train, X_test, y_train, y_test = train_test_split(X,Y,test_size=0.2, random_st
mlp=MLPClassifier(hidden_layer_sizes=(10,10,10), activation = 'relu', max_iter=5
mlp.fit(X_train,y_train)# Modelo entrenado

from sklearn.externals import joblib
joblib.dump(mlp,'modelo_entrenado.pkl')
predictions=mlp.predict(X_test)
print(classification_report(y_test,predictions))

##### MSV Support Vector Machines

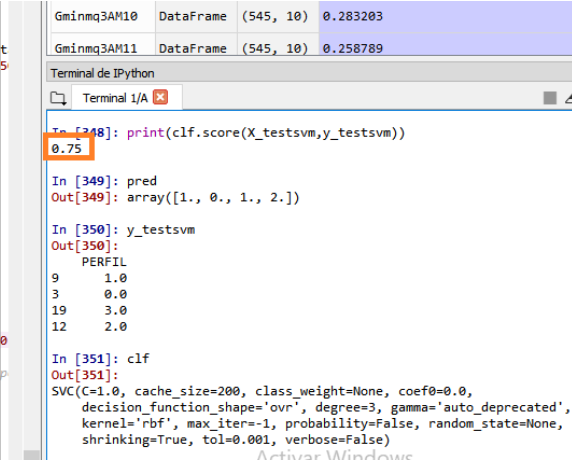
Z=x_std.astype(float)

### CLASIFICADOR SVM

X_trainsvm, X_testsvm, y_trainsvm, y_testsvm = train_test_split(Z,Y,test_size=0

clf=SVC(kernel='rbf').fit(X_trainsvm,y_trainsvm) # modelo entrenado lineal, 'p
print(clf.score(X_testsvm,y_testsvm))

pred=clf.predict(X_testsvm)
```



```
In [348]: print(clf.score(X_testsvm,y_testsvm))
0.75

In [349]: pred
Out[349]: array([1., 0., 1., 2.])

In [350]: y_testsvm
Out[350]:
PERFIL
9      1.0
3      0.0
19     3.0
12     2.0

In [351]: clf
Out[351]:
SVC(C=1.0, cache_size=200, class_weight=None, coef0=0.0,
    decision_function_shape='ovr', degree=3, gamma='auto_deprecated',
    kernel='rbf', max_iter=-1, probability=False, random_state=None,
    shrinking=True, tol=0.001, verbose=False)
```

Figura 99.SVM Kernel rbf radial basis function kernel (Fuente autor).

Analizando el score se observa que el algoritmo realiza un acierto del 50% lo cual no es muy eficiente en la clasificación de datos, procedemos a cambiar el núcleo que utilizara el algoritmo, por la función kernel 'rbf'

Se observa el score evidencia un acierto del 75% lo cual es una buena opción para implementar la clasificación de datos, pero a un persiste un 25% sin acierto, procedemos a cambiar el núcleo que utilizara el algoritmo, por la función kernel 'sigmoid', y linear obteniendo un 75% de acierto no se presenta cambio.

Como opción final se opta por cambiar el tipo de pre procesado de datos de standarscaler al método Manhattan, obteniendo un porcentaje de acierto optimo del 100%

```

from sklearn.externals import joblib
joblib.dump(mlp, 'modelo_entrenado.pkl')
predictions=mlp.predict(X_test)
print(classification_report(y_test,predictions))

#####  SVM Support Vector Machines

Z=x_std.astype (float)

### CLASIFICADOR SVM

X_trainsvm, X_testsvm, y_trainsvm, y_testsvm = train_test_split(Z,Y,test_size=0.2)
clf=SVC(kernel='linear').fit(X_trainsvm,y_trainsvm) # modelo entrenado linear
print(clf.score(X_testsvm,y_testsvm))

pred=clf.predict(X_testsvm)

In [357]: y_testsvm
Out[357]:
PERFIL
9      1.0
3      0.0
19     3.0
12     2.0

In [358]: pred
Out[358]: array([1., 0., 3., 2.])

In [359]: clf
Out[359]:
SVC(C=1.0, cache_size=200, class_weight=None, coef0=0.0,
    decision_function_shape='ovr', degree=3, gamma='auto_deprecated',
    kernel='linear', max_iter=-1, probability=False, random_state=None,
    shrinking=True, tol=0.001, verbose=False)

In [360]: print(clf.score(X_testsvm,y_testsvm))
1.0

```

Figura 100.SVM Kernel rbf radial basis function kernel (Fuente autor).

### Modelo del algoritmo maquia de soporte vectorial entrenado.

- SVC(C=1.0, cache\_size=200, class\_weight=None, coef0=0.0,
- decision\_function\_shape='ovr', degree=3, gamma='auto\_deprecated',
- kernel='rbf', max\_iter=-1, probability=False, random\_state=None,
- shrinking=True, tol=0.001, verbose=False)

**Socialización de resultados con el gremio de cacao cultores y jueces sensoriales de Norte de Santander**

**FEDECACAO-AGROINDUSTRIA VILLADIOSA**



Figura 101.Socialización proyecto

**Participan**

<b>Nombre</b>	<b>Cargo</b>	<b>Entidad</b>
Ing Miller Otero Gómez	Jefe de unidad departamental de FEDECACAO	FEDECACAO
Jorge Asdrubal Duque	Extensionista-Experto en cacao	FEDECACAO
José Villalba Sánchez	Empresario	Agroindustria VillaDiosa
Licenciado Emiro Villalba Quintero	Presidente del comité departamental de cacaoteros de Norte de Santander.	Comité departamental de cacaoteros
Ing Jorge Villalba Sánchez	Representante legal	Agroindustria VillaDiosa

## Conclusiones

Es importante durante el proceso de fermentación del cacao garantizar el protocolo establecido por FEDECACAO, donde se definen tiempos de volteo de la masa de cacao para garantizar buena fermentación. Durante las primeras 48 horas se realiza el proceso químico anaeróbico, la temperatura en masa de cacao alcanza aproximadamente de 41 grados Celsius, permitiendo secar el embrión y prevenir que se desarrolle la planta o se germine, de esta forma se garantiza el sabor y olor del producto.

Realizando el análisis del conjunto de señales adquiridas por la cámara de medida, se puede concluir que los sensores que más reaccionan en cuanto a la amplitud de voltaje, son los asociados con la calidad del aire, alcoholes, monóxido de carbono, butanos y bencenos.

Los tiempos definidos para adquisición de datos del sistema de olfato electrónico, se realizan tomando como referencia la línea base de las señales adquiridas, en esta fase se obtiene una ganancia máxima y mínima de señal, adicional es importante lograr una buena recuperación del conjunto de sensores de gas, para llevarlos a condiciones iniciales.

En la implementación del controlador de temperatura asociado a la cámara de concentración de volátiles, se utilizó el método de Ziegler and Nichols para sintonizar el lazo de control Proporcional Integral PI, obteniendo una respuesta de señal de proceso en estado estable aproximadamente en 70 segundos. Se procede a comparar la respuesta del sistema, implementando un controlado Proporcional Integral Derivativo PID, por método de CHIEN, observando un tiempo de establecimiento aproximadamente en 50 segundos, con los resultados se selecciona el controlador PID debido a que la respuesta es más rápida en alcanzar el valor estable de la señal de proceso.

Al implementar el procesamiento de señal mediante el método de análisis de componentes principales se observa que utilizando pre-procesado de datos Manhattan, la respuesta obtenida en el hiperplano las clases están correctamente agrupadas sin solapamiento, en comparación con el escalador estándar donde presento solapamiento entre las clases fermentado 144 h y sobrefermentado.

El Análisis de Clúster o Conglomerados, es una técnica estadística multivariante que busca agrupar elementos (o variables) tratando de lograr la máxima homogeneidad en cada grupo, como resultado se puede observar la distribución de las estructuras asociadas a cada una de las clases vinculadas al proceso de fermentación, se observa solapamiento de la clase A fermentado 144 horas y la clase C sobrefermentado.

El análisis discriminante es una técnica, sustancialmente, clasificatoria, vemos en los resultados separación de clases de forma distante, obteniendo óptimos resultados en la clasificación.

Para red neuronal MPLC, se puede concluir que a un aumento de neuronas en capas ocultas mejor serán los resultados del entrenamiento, el pre-procesado de datos igualmente es importante para la clasificación.

Finalmente, el sistema de olfato electrónico es sometido a jueces sensoriales que realizan la validación de los resultados obtenidos.

## Referencias bibliográficas

- Afoakwa, E. O., Paterson, A., Fowler, M., & Ryan, A. (2008). Flavor Formation and Character in Cocoa and Chocolate: A Critical Review. *Critical Reviews in Food Science and Nutrition*, 48(9), 840-857. <https://doi.org/10.1080/10408390701719272>
- Alfaro Ruíz, V. M. (2011). IDENTIFICACIÓN DE PROCESOS SOBREAMORTIGUADOS UTILIZANDO TÉCNICAS DE LAZO ABIERTO. *Revista Ingeniería*, 11(1-2). <https://doi.org/10.15517/ring.v11i1-2.605>
- Amat, R. Y. (2017). Análisis de Componentes Principales (Principal Component Analysis, PCA) y t-SNE. Recuperado 23 de septiembre de 2019, de [https://www.cienciadedatos.net/documentos/35\\_principal\\_component\\_analysis](https://www.cienciadedatos.net/documentos/35_principal_component_analysis)
- Brezmes, L. J. (2001). *Diseño de una nariz electrónica para la determinación no destructiva del grado de maduración de la fruta*.
- Carlson, A. (2018, julio 18). Poor Man's Peltier Mini Fridge—Part 1 of 2. Recuperado 24 de septiembre de 2019, de ElectroSchematics.com website: <https://www.electroschematics.com/poor-mans-peltier-mini-fridge-part-1-of-2/>
- Castañeda, J., & Rodríguez Jacobo. (2016). *Análisis del perfil de compuestos volátiles fermentado y secado de cacao*. 4, 6.
- Crespo, F. L. (2013). *ANÁLISIS DISCRIMINANTE*. 48.
- Durán, A. C. M., & Gualdron, G. O. (2014). Nariz electrónica para determinar el índice de madurez del tomate de árbol (*Cyphomandra Betacea Sendt*). *Ingeniería, Investigación y Tecnología*, 15(3), 351-362. [https://doi.org/10.1016/S1405-7743\(14\)70346-4](https://doi.org/10.1016/S1405-7743(14)70346-4)
- Durán, C. M. (2005). Diseño y optimización de los subsistemas de un sistema de olfato electrónico para aplicaciones agroalimentarias e industriales. *Tesis doctoral*.

- Fabisch, A., & Passos Alexandre. (2017). 1.17. Modelos de redes neuronales (supervisadas)—Documentación de scikit-learn 0.21.3. Recuperado 25 de septiembre de 2019, de [https://scikit-learn.org/stable/modules/neural\\_networks\\_supervised.html](https://scikit-learn.org/stable/modules/neural_networks_supervised.html)
- Fernández-Muñoz, J.-Á., Herrero-Agustín, J.-L., Lozano-Rogado, J., Santos-Blanco, J.-P., & Suárez-Marcelo, J.-I. (2017). Un sistema de clasificación de olores en línea para narices electrónicas. (Spanish). *An online odor classification system for electronic noses. (English)*, 92(3), 354-360. <https://doi.org/10.6036/8075>
- Fuente, F. (2011). *Análisis\_Cluster*.
- González, L. (2018, marzo 23). Aprendizaje Supervisado: Random Forest Classification. Recuperado 24 de septiembre de 2019, de Ligdi González website: <http://ligdigonzalez.com/aprendizaje-supervisado-random-forest-classification/>
- Hale, J. (2019, julio 16). Scale, Standardize, or Normalize with Scikit-Learn. Recuperado 23 de septiembre de 2019, de Medium website: <https://towardsdatascience.com/scale-standardize-or-normalize-with-scikit-learn-6ccc7d176a02>
- Llamas, L. (2016). Detector de gases con Arduino y la familia de sensores MQ. Recuperado 24 de septiembre de 2019, de Luis Llamas website: <https://www.luisllamas.es/arduino-detector-gas-mq/>
- Millán, M. (2016). *Diseño e implementación de un sistema de medida de gases con Arduino*. 126.
- Morales, M. A. J. (2012). *ACERCAMIENTO A LAS MÁQUINAS DE SOPORTE VECTORIAL Y SUS APLICACIONES EN PROYECTOS DE GRADO DEL PROGRAMA DE INGENIERÍA DE SISTEMAS Y COMPUTACION DE LA UNIVERSIDAD TECNOLÓGICA DE PEREIRA*. 107.



- Moreno, I., Caballero, R., Galán, R., Matía, F., & Jiménez, A. (2009). La Nariz Electrónica: Estado del Arte. *Revista Iberoamericana de Automática e Informática Industrial RIAI*, 6(3), 76-91. [https://doi.org/10.1016/S1697-7912\(09\)70267-5](https://doi.org/10.1016/S1697-7912(09)70267-5)
- Ochoa, J. A. C. (2011). *Reconocimiento de Patrones*. 13.
- Odwyen, A. (2009). *Aidan\_O\_Dwyer\_Handbook\_of\_PI\_and\_PID\_Controller\_Tuning\_Rules* (3.<sup>a</sup> ed.).
- Olunloyo. (2011). Neural\_network-based\_electronic\_nose\_for\_cocoa\_bea. 4, Vol.13, 18.
- Pérez, O. B., & Rentería Rodríguez Miguel. (2018). *Inteligencia artificial*. 12.
- Pinzón, U. J. O. (2012). *Investigación, transferencia de tecnología comercialización*. 12, 28.
- Pravin. (2018, agosto 28). How to calculate Euclidean and Manhattan distance by using python. Recuperado 23 de septiembre de 2019, de Technology Trekking website: <https://www.techtrekking.com/how-to-calculate-euclidean-and-manhattan-distance-by-using-python/>
- Quicazán, M. C., & Zuluaga, C. M. (2011). *La nariz electrónica, una novedosa herramienta para el control de procesos y calidad en la industria agroalimentaria*. 18(2), 9.
- Ríos, F. (2017). *Estrategias país para la oferta de cacao especiales*. 1.
- Ruiz, C. A., Basualdo, M. S., & Matich, D. J. (2001). *Redes Neuronales: Conceptos Básicos y Aplicaciones*. 55.
- Salas, R. (2015). *Redes Neuronales Artificiales*. 7.
- Suárez, E. J. C. (2014). *Tutorial sobre Máquinas de Vectores Soporte (SVM)*. 25.
- Valdez, L. F., & Gutiérrez, J. M. (2016). Chocolate Classification by an Electronic Nose with Pressure Controlled Generated Stimulation. *Sensors (Basel, Switzerland)*, 16(10). <https://doi.org/10.3390/s16101745>
- Villanueva, M. S. (2014). *Arduino diseño de un sistema de captura y procesamiento de señales*. 72.

Wacher, R. M. del C. (2011). *Microorganismos y chocolate*. 12(1).

## Anexos

### LM35 Precision Centigrade Temperature Sensors

#### 1 Features

- Calibrated Directly in Celsius (Centigrade)
- Linear + 10-mV/°C Scale Factor
- 0.5°C Ensured Accuracy (at 25°C)
- Rated for Full -55°C to 150°C Range
- Suitable for Remote Applications
- Low-Cost Due to Wafer-Level Trimming
- Operates From 4 V to 30 V
- Less Than 60-μA Current Drain
- Low Self-Heating, 0.08°C in Still Air
- Non-Linearity Only ±¼°C Typical
- Low-Impedance Output, 0.1 Ω for 1-mA Load

#### 2 Applications

- Power Supplies
- Battery Management
- HVAC
- Appliances

#### 3 Description


The LM35 series are precision integrated-circuit temperature devices with an output voltage linearly-proportional to the Centigrade temperature. The LM35 device has an advantage over linear temperature sensors calibrated in Kelvin, as the user is not required to subtract a large constant voltage from the output to obtain convenient Centigrade scaling. The LM35 device does not require any external calibration or trimming to provide typical accuracies of ±¼°C at room temperature and ±¾°C over a full -55°C to 150°C temperature range. Lower cost is assured by trimming and calibration at the wafer level. The low-output impedance, linear output, and precise inherent calibration of the LM35 device makes interfacing to readout or control circuitry especially easy. The device is used with single power supplies, or with plus and minus supplies. As the LM35 device draws only 60 μA from the supply, it has very low self-heating of less than 0.1°C in still air. The LM35 device is rated to operate over a -55°C to 150°C temperature range, while the LM35C device is rated for a -40°C to 110°C range (-10° with improved accuracy). The LM35-series devices are available packaged in hermetic TO transistor packages, while the LM35C, LM35CA, and LM35D devices are available in the plastic TO-92 transistor package. The LM35D device is available in an 8-lead surface-mount small-outline package and a plastic TO-220 package.

#### Device Information<sup>(1)</sup>


PART NUMBER	PACKAGE	BODY SIZE (NOM)
LM35	TO-CAN (3)	4.699 mm × 4.699 mm
	TO-92 (3)	4.30 mm × 4.30 mm
	SOIC (8)	4.90 mm × 3.91 mm
	TO-220 (3)	14.986 mm × 10.16 mm

(1) For all available packages, see the orderable addendum at the end of the datasheet.

#### Basic Centigrade Temperature Sensor (2°C to 150°C)



#### Full-Range Centigrade Temperature Sensor



Choose  $R_1 = -V_S / 50 \mu\text{A}$   
 $V_{\text{OUT}} = 1500 \text{ mV at } 150^\circ\text{C}$   
 $V_{\text{OUT}} = 250 \text{ mV at } 25^\circ\text{C}$   
 $V_{\text{OUT}} = -550 \text{ mV at } -55^\circ\text{C}$







An IMPORTANT NOTICE at the end of this data sheet addresses availability, warranty, changes, use in safety-critical applications, intellectual property matters and other important disclaimers. PRODUCTION DATA.



Performance Specifications

Hot Side Temperature (°C)	25° C	50° C
Qmax (Watts)	50	57
Delta Tmax (°C)	66	75
I <sub>max</sub> (Amps)	6.4	6.4
V <sub>max</sub> (Volts)	14.4	16.4
Module Resistance (Ohms)	1.98	2.30



# TECHNICAL DATA

# MQ-135 GAS SENSOR

## FEATURES

Wide detecting scope      Fast response and High sensitivity  
 Stable and long life      Simple drive circuit

## APPLICATION

They are used in air quality control equipments for buildings/offices, are suitable for detecting of NH<sub>3</sub>, NO<sub>x</sub>, alcohol, Benzene, smoke, CO<sub>2</sub>, etc.

## SPECIFICATIONS

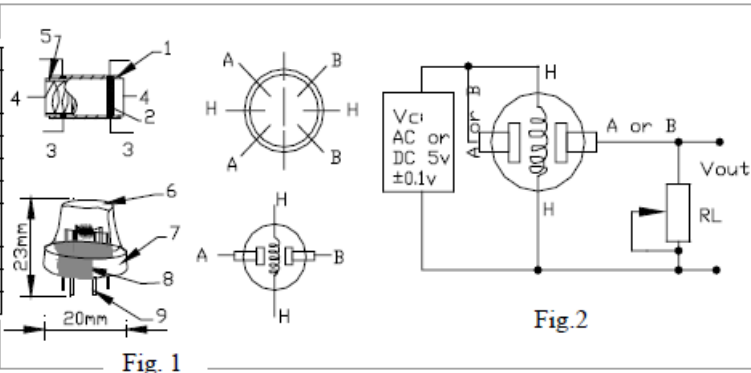
### A. Standard work condition

Symbol	Parameter name	Technical condition	Remarks
V <sub>c</sub>	Circuit voltage	5V±0.1	AC OR DC
V <sub>H</sub>	Heating voltage	5V±0.1	AC OR DC
R <sub>L</sub>	Load resistance	can adjust	
R <sub>H</sub>	Heater resistance	33Ω±5%	Room Tem
P <sub>H</sub>	Heating consumption	less than 800mw	

### B. Environment condition

Symbol	Parameter name	Technical condition	Remarks
T <sub>ao</sub>	Using Tem	-10□-45□	
T <sub>as</sub>	Storage Tem	-20□-70□	
R <sub>H</sub>	Related humidity	less than 95%Rh	
O <sub>2</sub>	Oxygen concentration	21%(standard condition)Oxygen concentration can affect sensitivity	minimum value is over 2%

Parts	Materials
1 Gas sensing layer	SnO <sub>2</sub>
2 Electrode	Au
3 Electrode line	Pt
4 Heater coil	Ni-Cr alloy
5 Tubular ceramic	Al <sub>2</sub> O <sub>3</sub>
6 Anti-explosion network	Stainless steel gauze (SUS316 100-mesh)
7 Clamp ring	Copper plating Ni
8 Resin base	Bakelite
9 Tube Pin	Copper plating Ni





### SD-15

Model No.	Wattage	Vin	Vout	Iout	Isolation voltage	Operating temperature	Safety
SD-15A-5	15W	12V (9.2~18V)	5V	3A	1.5KVAC	-10~+60°C	CE / EAC
SD-15A-12			12V	1.25A			
SD-15A-24			24V	0.625A			
SD-15B-5	15W	24V (18~36V)	5V	3A	1.5KVAC	-10~+60°C	CE / EAC
SD-15B-12			12V	1.25A			
SD-15B-24			24V	0.625A			
SD-15C-5	15W	48V (36~72V)	5V	3A	1.5KVAC	-10~+60°C	CE / EAC
SD-15C-12			12V	1.25A			
SD-15C-24			24V	0.625A			

### SD-25

Model No.	Wattage	Vin	Vout	Iout	Isolation voltage	Operating temperature	Safety
SD-25A-5	25W	12V (9.2~18V)	5V	5A	1.5KVAC	-10~+60°C	CE / EAC
SD-25A-12	25W		12V	2.1A			
SD-25A-24	26W		24V	1.1A			
SD-25B-5	25W	24V (18~36V)	5V	5A	1.5KVAC	-10~+60°C	CE / EAC
SD-25B-12	25W		12V	2.1A			
SD-25B-24	26W		24V	1.1A			
SD-25C-5	25W	48V (36~72V)	5V	5A	1.5KVAC	-10~+60°C	CE / EAC
SD-25C-12	25W		12V	2.1A			
SD-25C-24	26W		24V	1.1A			

## Plano de conexiones CANOSE

