

**Prototipo de una nariz electrónica para la detección de fugas de gas natural en ambientes
residenciales**

Adriana María Morales Ortiz

Universitaria Agustiniana
Facultad de Ingenierías
Programa de Ingenierías en telecomunicaciones
Bogotá D.C.
2020

**Prototipo de una nariz electrónica para la detección de fugas de gas natural en ambientes
residenciales**

Adriana María Morales Ortiz

Director

Ing. Ramiro Osorio Díaz

Trabajo de grado para optar al título de Ingeniera en telecomunicaciones

Universitaria Agustiniana

Facultad de Ingenierías

Programa de Ingenierías en telecomunicaciones

Bogotá D.C.

2020

Dedicatoria

Dedico de manera especial a mi familia. A mis padres por su constante apoyo físico, emocional y económico. A mis hermanos por su motivación, palabras de apoyo y compañía. A mis mascotas, Samantha, Marlú y Cory, por su afecto, compañía, cariño y amor incondicional. Sin ustedes esto no hubiese sido posible. ¡Gracias por todo! Con amor, Adriana María Morales Ortiz.

Agradecimientos

Agradezco de manera especial a Dios, por sus bendiciones dadas, en primer lugar, por darme la vida y salud, por darme fortaleza y darme la oportunidad de culminar esta maravillosa etapa de mi vida. No me cabe duda de que en cada paso que realice él estuvo presente, acompañándome, guiándome y corrigiendo mis faltas. Agradezco a mi familia por su constante apoyo en el transcurso de esta etapa de mi vida, en los momentos tanto felices como difíciles, nunca me dejaron desfallecer. A la universidad, por su confianza y lealtad, a los profesores por su tiempo y dedicación, por acompañarnos en esta etapa, brindándonos sus conocimientos.

Resumen

El presente documento tiene como finalidad demostrar todo el proceso que se realizó, para el diseño e implementación de un prototipo de una nariz electrónica para la detección de gas natural en ambientes residenciales. Donde dicha implementación se realizó bajo el uso de un modelo de arreglo de sensores de gas, estos sensores sensibles a la presencia de diferentes gases volátiles presentes en el aire, y posteriormente utilizando técnicas de inteligencia artificial, como lo son las redes neuronales artificiales (RNA) para la clasificación y la predicción de los diferentes gases sensados por el arreglo de sensores de gas en el entorno ambiental, con el objetivo de obtener lecturas fiables del tipo de gas y la concentración de dicho gas en específico que se encuentre presente en el aire, en este caso el gas natural en el entorno residencial. Finalizando con la presentación del análisis de los resultados obtenidos en el prototipo.

Palabras clave: arreglo de sensores, redes neuronales artificiales, inteligencia artificial, gases volátiles, gas natural, concentración de gas.

Abstract

The purpose of this document is to demonstrate the entire process that was carried out, for the design and implementation of a prototype of an electronic nose for the detection of natural gas in residential environments. Where such implementation was carried out under the use of a gas sensor arrangement model, these sensors sensitive to the presence of different volatile gases present in the air, and subsequently using artificial intelligence techniques, such as artificial neural networks (RNA) for the classification and prediction of the different gases sensed by the arrangement of gas sensors in the environmental environment, with the aim of obtaining reliable readings of the type of gas and the concentration of that specific gas present in the air, in this case natural gas in the residential environment. Ending with the presentation of the analysis of the results obtained in the prototype.

Keywords: sensor array, artificial neural networks, artificial intelligence, volatile gases, natural gas, gas concentration.

Tabla de contenido

Introducción	13
Planteamiento del problema	14
Justificación.....	16
Objetivos	17
Objetivo general	17
Objetivos específicos.....	17
Marco de referencia.....	18
Estado del arte	18
Marco teórico.....	24
Arreglo de sensores.....	24
Arduino.....	24
Redes neuronales artificiales (RNA o ANN).....	25
Orange.....	25
Marco Legal.....	26
Metodología del proyecto.....	28
Metodología cuantitativa	28
Metodología experimental.....	28
Administración del proyecto	29
Cronograma de actividades	29
Presupuesto.....	30
Presupuesto de recursos humanos.....	30
Presupuesto de equipos.....	30
Presupuesto de software.....	30
Presupuesto de materiales y suministros.	31
Presupuesto Total.....	31
Desarrollo del prototipo: Nariz electrónica.....	32
Capítulo I – Conceptualización de los elementos del prototipo.....	32
Fundamentos de la nariz electrónica.....	32
Fundamentos de las redes neuronales artificiales.	35
Capítulo II – Ejecución del prototipo	43

Arreglo de sensores de gas.....	43
Calibración de los sensores MQ.	47
Pruebas funcionamiento de sensores.	54
Adquisición y almacenamiento de datos.	59
Diseño y entrenamiento de una red neuronal artificial.	64
Capítulo III – Análisis de resultados del prototipo.....	79
Conclusiones	80
Recomendaciones a trabajos futuros	81
Referencias	82
Anexos.....	84

Lista de figuras

Figura 1. Conformación representativa de un sistema de olfato electrónico.	18
Figura 2. Diseño de bloques del circuito a implementar.	20
Figura 3. Esquemático sensor gas catalítico.....	33
Figura 4. Esquemático sensor gas infrarrojo	33
Figura 5. Esquemático sensor gas electroquímico	34
Figura 6. Esquemático sensor gas semiconductor	34
Figura 7. Esquemático sensor de temperatura y humedad	34
Figura 8. Estructura general de una neurona.	35
Figura 9. Función escalón	37
Figura 10. Función lineal y mixta	37
Figura 11. Función sigmoideal.....	38
Figura 12. Función hiperbólica tangente	38
Figura 13. Función ReLU.....	38
Figura 14. Estructura de la red neuronal perceptrón monocapa	42
Figura 15. Estructura de la red neuronal perceptrón multicapa.....	43
Figura 16. Ilustrativo sensor de gas serie MQ.....	44
Figura 17. Tarjeta electrónica Arduino Uno.....	45
Figura 18. Bosquejo del arreglo de sensores.	45
Figura 19. Implementación circuito de arreglo de sensores.	46
Figura 20. Indicativo de RL(1K Ω) en el sensor MQ.....	47
Figura 21. Curva características MQ2.....	48
Figura 22. Curva características MQ3.....	48
Figura 23. Curva características MQ6.....	49
Figura 24. Sketch IDE Arduino, cálculo RS y R0 en aire ambiente.	50
Figura 25. Impresión calculo R0 en aire ambiente.....	50
Figura 26. Respuesta monitor serie, resultados del cálculo R0.....	51
Figura 27. Proporción del aire ambiente actual.....	51
Figura 28. Impresión de la proporción en aire ambiente.....	52
Figura 29. Respuesta monitor serie, resultados para la proporción de aire ambiente.	52
Figura 30. Cálculo para la concentración de gas PPM.....	53

Figura 31. Ilustrativo sensor DHT22.....	54
Figura 32. Configuración del sensor DHT22.	54
Figura 33. Respuesta del sensor MQ2 sin presencia de gas monóxido de carbono (CO).....	55
Figura 34. Respuesta del sensor MQ2 con presencia de gas monóxido de carbono (CO).....	55
Figura 35. Respuesta del sensor MQ3 sin presencia de gas metano (CH4).....	56
Figura 36. Respuesta del sensor MQ3 con presencia de gas metano (CH4).....	56
Figura 37. Respuesta del sensor MQ6 sin presencia de gas propano y butano (GLP).....	57
Figura 38. Respuesta del sensor MQ6 con presencia de gas propano y butano (GLP).....	57
Figura 39. Respuesta del sensor dht22, para la temperatura y humedad.....	58
Figura 40. Bosquejo para la integración del módulo ethernet al circuito, arreglo de sensores.	59
Figura 41. Implementación de integración del módulo ethernet al circuito, arreglo de sensores.	60
Figura 42. Librerías y asignación de direcciones fijas (ethernet).....	60
Figura 43. Conexión cliente – servidor.	61
Figura 44. Estructura para la tabla de base de datos.....	62
Figura 45. Conexión privada PHP.....	62
Figura 46. Conexión con la base de datos e introducción de lecturas a la tabla.	63
Figura 47. Conexión Arduino y base de datos.	63
Figura 48. Almacenamiento de lecturas en la tabla.....	63
Figura 49. Arquitectura de la red neuronal artificial.	64
Figura 50. Ejemplo dataset.	65
Figura 51. Diagrama diseño de red neuronal artificial para la predicción y clasificación.	66
Figura 52. Widget para insertar el dataset.	67
Figura 53. Widget para visualizar el dataset.	67
Figura 54. Asignación de entradas y valores.....	68
Figura 55. Algoritmo de entrenamiento de la RNA.	69
Figura 56. Representación gráfica, entrenamiento de la RNA (10/10).	71
Figura 57. Representación gráfica, entrenamiento de la RNA (50/10).	72
Figura 58. Representación gráfica, entrenamiento de la RNA (50/20).	72
Figura 59. Representación gráfica, entrenamiento de la RNA (50/50).	73

Figura 60. Representación gráfica, entrenamiento de la RNA (50/100).	73
Figura 61. Representación gráfica, entrenamiento de la RNA (100/100).	74
Figura 62. Representación gráfica, entrenamiento de la RNA (100/150).	74
Figura 63. Representación gráfica, entrenamiento de la RNA (100/200).	75
Figura 64. Resultados de predicción para el tipo de gas - 0.	76
Figura 65. Resultados de predicción para el tipo de gas - 1.	766
Figura 66. Resultados de predicción para el tipo de gas - 2.	767

Lista de tablas

Tabla 1. Cronograma del proyecto	29
Tabla 2. Presupuesto de recursos humanos	30
Tabla 3. Presupuesto de equipos.....	30
Tabla 4. Presupuesto de software	30
Tabla 5. Presupuesto de materiales y suministros	31
Tabla 6. Presupuesto total.....	31
Tabla 7. Set de sensores MQ y su respectiva sensibilidad	44
Tabla 8. Parámetros de entrenamiento	75

Introducción

Este proyecto surge por la necesidad de mitigar los riesgos que corren los seres vivos al exponerse a concentraciones elevadas de gases volátiles en el aire, como es el gas natural en ambientes residenciales. Debido a esto, este proyecto tiene el objetivo de diseñar un prototipo de una nariz electrónica la cual permita, identificar, predecir y clasificar el gas natural en ambientes residenciales, partiendo del uso de sensores de gas, los cuales se configuran para generar lecturas de concentraciones de gas natural presente en el aire, donde por medio de una tarjeta de adquisición de datos, podamos almacenar y visualizar dichas lecturas en un computador, y con dichas lecturas se proceda a realizar la creación y entrenamiento de una red neuronal artificial para la clasificación y predicción de nivel de concentración de los diferentes gases presentes en el aire, de esa forma pudiendo diferenciar entre una fuga de gas al uso común de gasodomésticos.

Planteamiento del problema

El gas natural es un hidrocarburo, mezcla de gases ligeros de origen natural, principalmente compuesto por metano, propano, butano y carbono. A mediados del siglo XIX este tipo de gas comenzó a extraerse y canalizarse con el propósito de comercializarlo en el sector industrial y en el hogar, posteriormente dando así diferentes aplicaciones en el hogar familiar. Para este gas el principal uso en hogares es: la activación de estufas eléctricas en cocinas, calefacción mediante calderas, y como gas natural vehicular. Sin embargo, son graves las consecuencias que corren los seres vivos a la exposición prolongada a la presencia del gas natural. Se evidencia en los medios de comunicación virtuales, como el periódico argentino: (Infobae, 2018) donde describe los mayores riesgos que corren los seres humanos a la exposición de este gas. Haciendo énfasis que el principal riesgo de inhalar este gas es la intoxicación, y con ello afectando en gran medida la respiración.

Dependiendo así de la concentración de gas que se encuentre en el lugar. Cuando se presenta en pequeñas cantidades, la población expuesta a la presencia del gas puede presentar síntomas como un simple dolor de cabeza, náuseas y falta de oxígeno. Cuando se presenta en grandes cantidades los síntomas y las consecuencias son mayores, ya que, al estar por un tiempo muy prolongado, la población afectada puede presentar síntomas como la pérdida de reflejos, la pérdida de conciencia, convulsiones o puede desatar la muerte del individuo afectado (Infobae, 2018).

Noticias recientes muestran como la población se ve afectada por la mala manipulación de este gas, a comienzos del año 2019, en la ciudad de Guatemala, en el barrio de Gerona. A causa de una fuga de gas en un calentador de gas, provocó una fuerte explosión en un edificio de departamentos residenciales. Esta grave explosión dejó como afectados a una mujer y un hombre con heridas de gravedad, también dejando con severas crisis nerviosas a residentes del conjunto. (TN23todoennoticias, 2019)

A medida que aumentan las alertas por siniestros por fugas de gas, aumenta la preocupación y surgen medidas necesarias a tomar si se presentan estos siniestros por fuga de gas en viviendas. Un claro ejemplo de esto es el blog: (Media, 2017) donde enumera 7 consejos en caso de detectar una fuga de gas. Las recomendaciones sugeridas son: 1. apagar inmediatamente toda fuente de ignición, 2. Apagar fuentes eléctricas o electrónicas, 3. Cerrar el suministro de gas, 4. Abrir puertas y ventanas, 5. Llamar de inmediato a servicios de emergencias, 6. Salir del área, y 7. Evacuar la zona. Donde se evidencia acciones inmediatas por la presencia de una fuga de gas natural en entornos no

controlados.

Sin embargo, cuando la persona está inconsciente (durmiendo), la detección de la presencia de este gas se hace menor, por lo cual una persona expuesta a un ambiente contaminado puede fallecer en un lapso de 6 a 8 horas (país, 2007). De acuerdo con esto, se plantea lo siguiente: **¿Cómo detectar los escapes de gas natural en entornos residenciales, empleando el uso de herramientas o instrumentos electrónicos de bajo costo?**

Justificación

En la actualidad, según cifras del ministerio de energía del país, Colombia supera los 10 millones de usuarios con servicio de gas natural en sus viviendas (Soto Salomón, 2020). Sin embargo, son grandes los riesgos que corren los usuarios debido al uso inadecuado de este hidrocarburo. A principios del año 2020, en la localidad de suba se presentó el primer caso registrado por el uso inadecuado de este hidrocarburo. Una mujer de 43 años resultó lesionada a causa de una fuerte explosión debido a una fuerte acumulación de gas en su vivienda (BluRadio, 2020). En consecuencia, a este tipo de casos registrados, es necesario implementar herramientas de protección al usuario, con ello salvaguardando su integridad física, psicológica y por lo tanto la de su familia. Por esta razón el presente proyecto, busca implementar un dispositivo capaz de discriminar la presencia de estos tipos de gases presentes en el aire, nocivos para la salud y alertar al usuario. Este dispositivo debe estar compuesto por una serie de sensores químicos de olor, de temperatura y de humedad combinados, y el entrenamiento de una red neuronal artificial. Los cuales deben garantizar una lectura fiable de la calidad del aire en el entorno, y disminuyendo la tasa de error de dicha lectura a causa de diferentes actividades que se realicen en las viviendas, involucrando el uso de gas combustible en concentraciones mínimas. Estos sensores en conjunto identificarán y analizarán una muestra de olor presente el aire, determinando si se presenta la presencia de algún tipo de gas combustible que pueda ser perjudicial para la salud de los seres vivos. Y de esa manera aumentando considerablemente la seguridad de la vivienda y contribuyendo al mejoramiento de calidad de los usuarios.

La implementación y ejecución de este proyecto, permite el crecimiento personal y profesional del ejecutor. Dando satisfacción de ofrecer un producto y/o servicio de calidad a la comunidad, desempeñando conocimientos técnicos, tanto teóricos como prácticos propios. De igual forma adquiriendo conocimientos desconocidos hasta el momento en el área de la electrónica y las comunicaciones. Adquiriendo experiencia y destreza, en el uso constante de herramientas para la creación del desarrollo de prototipos de sistemas de comunicación, digitales e interactivos, que se pueden desarrollar bajo instrumentos electrónicos como los sensores químicos, las plaquetas electrónicas de Arduino y su IDE (entorno de desarrollo interactivo), combinado con técnicas de inteligencia artificial, como las redes neuronales artificiales, dando a lugar a varias aplicaciones en el ámbito de las telecomunicaciones, considerando su capacidad de resolver problemas y proporcionar soluciones de manera autónoma.

Objetivos

Objetivo general

Implementar un prototipo de una nariz electrónica a partir de un arreglo de sensores de gas y redes neuronales artificiales, para la detección de fugas de gas natural en ambientes residenciales.

Objetivos específicos

1. Conceptualizar los elementos de una nariz electrónica y redes neuronales artificiales.
2. Diseñar un modelo de arreglo de sensores de gas, consecutivo con la adquisición de datos para el entrenamiento de una red neuronal artificial.
3. Evaluar factibilidad de funcionamiento del prototipo.

Marco de referencia

Estado del arte

(Quicazán, Díaz, & Zuluaga, 2016) Realizan una inspección bibliográfica acerca del funcionamiento de una nariz electrónica, y con ello exponiendo los avances y logros en el desarrollo de diferentes modelos de narices electrónicas durante los últimos de diez años. Y de esa forma definiendo los elementos electrónicos utilizados para su operación, de los cuales destaca un sistema de sensado y un sistema para procesamiento de la información obtenida del sistema de sensado utilizando técnicas de inteligencia artificial aplicando estadística multivariada. De acuerdo con lo anterior, definen una nariz electrónica como un sistema de olfato artificial, el cual émula la estructura de una nariz humana. Donde en ambos sistemas de nariz (electrónica y humana) se basan en receptores no específicos (sensores y células), seguido por un procesamiento de señales.

Un sistema de olfato artificial está formado por tres componentes principales: 1. Un sistema de medición, 2. Un sistema de caracterización y 3. Un sistema de reconocimiento de patrones. Como se muestra en la siguiente figura 1.

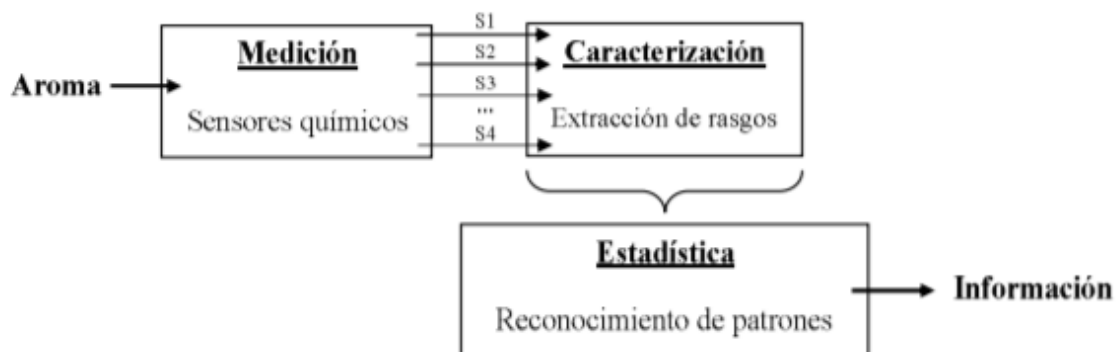


Figura 1. Conformación representativa de un sistema de olfato electrónico (Quicazán, Díaz, & Zuluaga, 2016).

Donde el sistema de medición se compone por un sistema de flujo de aire para la extracción de olor, este sistema traslada una muestra de gases volátiles hasta un arreglo de sensores químicos, los cuales transforman la información recibida en señales eléctricas. Seguido de un sistema de caracterización, es un sistema encargado extraer y caracterizar los rasgos de la muestra de gases analizada, mediante la cuantificación y transformación de datos de las señales de los diferentes sensores. Y finalmente un sistema para clasificar el aroma de los gases medidos mediante técnicas de reconocimiento de patrones.

(Quicazán, Díaz, & Zuluaga, 2016) dicen que el componente más importante en una nariz electrónica son los sensores. Los sensores, generalmente cada uno de ellos con cierta especificidad en un grupo de compuesto aromático, generan una respuesta representativa del compuesto medido a través de cambio de algún parámetro físico, por ejemplo, conductividad o corriente. “Los tiempos de respuesta van de segundos a minutos, y su valor cambia de acuerdo con el estímulo recibido que proviene de los compuestos aromáticos de la muestra”. 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. Por consiguiente, los resultados obtenidos de la huella digital deben ser analizados con técnicas de análisis estadístico multivariable.

Los métodos de análisis estadístico permiten analizar las respuestas de las señales eléctricas generadas por los sensores químicos de olor, se considera necesario aplicar técnicas de procesamiento de datos y posteriormente implementarlos con la aplicación que se vaya a utilizar. Los métodos analíticos más conocidos que definen (Quicazán, Díaz, & Zuluaga, 2016) son: “el análisis gráfico, el análisis estadístico multivariado (análisis de componentes principales (PCA), el análisis de función de discriminantes (DFA) y el análisis de clúster (CA)), análisis de redes (redes neuronales artificiales (ANN) y funciones de base radial (RBF))”. Las redes neuronales artificiales como técnica analítica para el reconocimiento de patrones:

Las redes neuronales artificiales (ANN) son estructuras de procesamiento de información paralela y distribuida, que intentan emular las funciones computacionales elementales de la red nerviosa del cerebro humano, con base en la interconexión de multitud de elementos de procesamiento, cada uno de los cuales observa un comportamiento completamente local. Los modelos de ANN combinan modelos matemáticos de las células nerviosas y modelos de arquitecturas que describen las interconexiones existentes entre estas células. Una red ANN se puede entrenar con el propósito de: solucionar problemas complejos, para tomar la decisión de asignar un dato de entrada a una clase establecida (clasificación), como un proceso de recuperación de información a partir de una entrada relacionada con datos almacenados (asociación) cuando no se conoce una clasificación de los datos de entrada la red genera esta clasificación (agrupamiento - clustering); puede solucionar problemas de optimización de naturaleza complicada, permite anticipar el estado futuro de un sistema y controlar sistemas dinámicos complejos. (Quicazán, Díaz, & Zuluaga, 2016, pág. 5).

(Vázquez, 2017) Presenta el diseño, construcción y posteriormente la implementación de un dispositivo aplicando tecnologías wearables con el propósito de adherir este dispositivo a

elementos de protección individual (chalecos, cascos, etc.) usualmente usados en el ámbito de la industria. Este dispositivo tendrá la capacidad de detectar gases nocivos y alertar al usuario de la presencia de estos gases en su entorno. Como se menciona anteriormente se busca aplicar tecnología wearable, por lo que es necesario aplicar el concepto de tecnología flexible, la cual permite producir circuitos electrónicos por medio de impresión convencional, a lo que hace referencia a la posibilidad de imprimir un circuito electrónico sobre áreas de cualquier tipo de superficie, ya sea rígida, plástica, flexible, etc. Posteriormente procede a diseñar un esquemático de un circuito prototipo, así dando un acercamiento de lo que sería el hardware del dispositivo final. Este esquemático lo segmenta en bloques: 1. Presencia de gas, 2. instrumentación, 3. sistemas de control, 4. interfaz de comunicaciones y por último 5. visualización en conjunto de alarmas. De esta forma, se puede visualizar en la siguiente imagen.

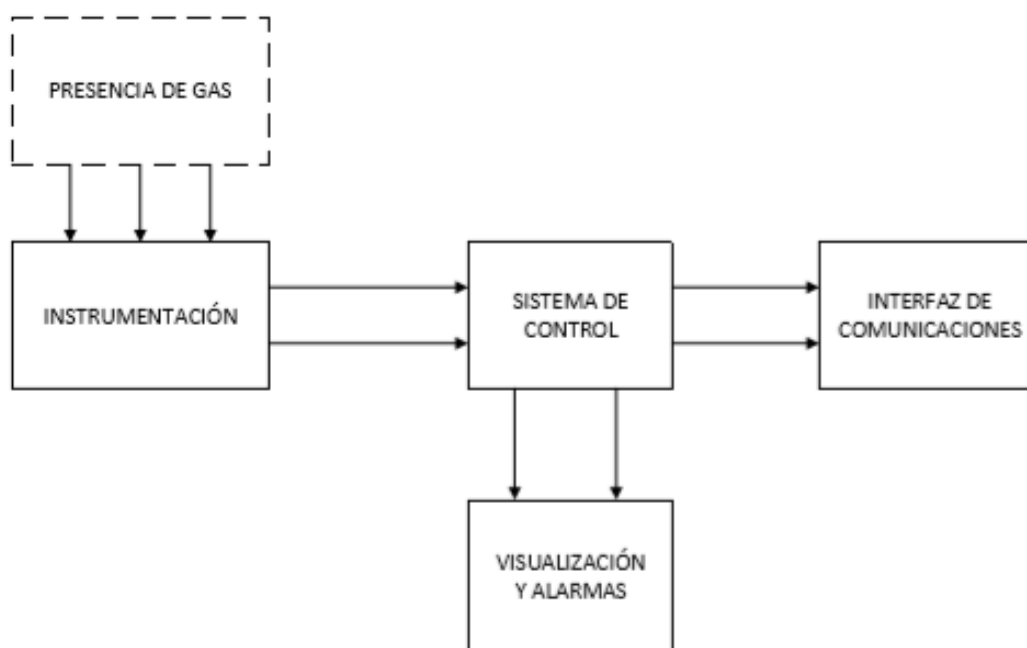


Figura 2. Diseño de bloques del circuito a implementar (Vázquez, 2017).

Después de realizar este esquemático, (Vázquez, 2017) define los componentes a utilizar, los cuales se componen de una placa Arduino ATmega328P la cual se utilizara para respectivas pruebas de presencia de gas en conjunto del sensor de gas con referencia MQ-135 (instrumento de mayor relevancia para el proyecto) con características fijas: detección de señal digital y analógica, y este sensor debe ser calibrado para la detección de un gas en específico tal como lo recomienda el fabricante, un módulo Bluetooth el cual permita la comunicación del detector de gas con otro

dispositivo con el que se quiera vincular (teléfono, computador, etc.). Después de realizar la construcción del circuito procede a realizar la esquematización del código fuente que estará implementado en el dispositivo detector de gas, para esta esquematización utiliza la herramienta “State Chart” la cual permite describir de forma gráfica el comportamiento que tendrá el dispositivo detector de gas. Para finalizar con la construcción de la correspondiente programación en el código fuente de Arduino. Posteriormente realiza las correspondientes pruebas de muestreo del dispositivo. Consiguiendo como resultado un dispositivo que presenta fallas con respecto a la uniformidad de la tinta usada en la placa de impresión, recalentamiento y alta sensibilidad a factores ajenos a el gas.

(Carbajar, Jimenez, Corona, & Noel, 2018) Presentan el prototipo de una nariz electrónica para obtener datos sobre la detección de olores de gas petróleo licuado (LP) usualmente usados en actividades domésticas, como lo es la cocina, calefacción de agua y combustibles en automóviles. Este prototipo se desarrolla con la implementación de elementos como son los sensores de gases: MQ-2 y MQ-3, MQ-7 y MQ-135 y la plataforma de hardware Arduino. El procedimiento para la realización de esta nariz electrónica consta de dos (2) etapas: 1. Captura de datos, 2. Generación y validación del modelo.

(Carbajar, Jimenez, Corona, & Noel, 2018) Proceden al montaje de prototipo el cual consta de una cámara de concentración de gas, circuito de control con Arduino y una PC para el análisis de datos. Posteriormente obtienen un “preprocesamiento de la señal” la cual consta de tomar diferentes muestras de gases, en este caso Petróleo licuado (LP) en la cámara de concentración, para luego extraer la respuesta del arreglo de sensores y finalizar con el procesamiento de la medida adquirida. Luego, se capturan los valores en medida de voltaje de la placa “Arduino” provenientes de los sensores para posteriormente normalizar aquellos datos, en un rango en 0-1, todo en conjunto del entrenamiento de una red neuronal basado en el algoritmo Backpropagation (BP). Obteniendo como resultado un modelo eficiente para la adquisición de datos (detección de gases) para posteriormente clasificarlos basados en el modelo de redes neuronales.

(Paredes, Sun Kou, Escobar, Doing, & Comina, 2016) Pretenden realizar una nariz electrónica la cual sea capaz de distinguir diferentes muestras de compuestos volátiles y reprimir el uso de controladores másicos de flujo. Implementaran una nariz electrónica con solo 4 sensores de gases, dos de ellos comerciales (MQ-2, MQ-3) y los otros dos fabricados en el laboratorio de la Universidad. El proceso para la recolección de datos lo hacen mediante pruebas de mediciones

empleando el método de sistema medición estático y dinámico, donde el primero consiste en almacenar la muestra de gas a utilizar en una cámara de concentración de gas hasta llegar a saturar está y posteriormente comience a medir y con ello arrojando resultados a la concentración de gas presente, esta cámara la construyeron de forma casera, en forma de cubo con paredes de plástico transparentes, al interior introdujeron el dispositivo hardware el cual consta de un arreglo de 4 sensores de gas químicos ubicados de manera circular, a esta cámara de gas le perforan dos agujeros correspondientes para la salida y entrada de gas. Esta cámara la sellaron herméticamente para así bloquear fugas. Y el segundo método consiste en almacenar la muestra en la cámara y el arreglo de sensores y estos comiencen a medir desde que empieza a fluir el gas, no desde que se satura la cámara de concentración. En este proyecto uno de los objetivos que plantearon, era eliminar los controladores másicos de flujo, ya que son muy costosos. Por lo cual implementan un sistema hidráulico a bajo costo, el cual está conformado por 3 válvulas de paso de dos vías, un solenoide y una mini-bomba de vacío, estos elementos están interconectados entre sí y a la cámara de concentración, con ello simulando el funcionamiento de los controladores másicos de flujo. Para posteriormente analizar los datos adquiridos de cada método utilizado (estático y dinámico). La adquisición de datos se realizó a través de la tarjeta de adquisición de datos marca National Instruments (USB 6213) y la respectiva programación desarrollada en el lenguaje de programación LabVIEW 2010 con la finalidad de representar gráficamente el comportamiento de cada gas. Después de realizar cada muestra y obtener la medición en cada uno del método de sistema utilizado (estático y dinámico), obteniendo como resultado un prototipo de nariz electrónica mucho más eficiente utilizando el método estático a diferencia del dinámico, con esto discriminando el gas de alcohol lineal dentro de un conjunto de sustancias olorosas diferentes a este gas.

(Rubio, Aguilar, Ávila, Stein, & Mélenz, 2016) Exponen el desarrollo de un prototipo de un sistema de sensado, este creado con el fin de identificar contaminantes en el aire. Este prototipo está formado por un arreglo de cinco sensores de gas de óxido de estaño y 1 sensor para medir la temperatura del ambiente y 1 sensor de humedad, utilizados para identificar vapores químicos. Donde los sensores recogen información del ambiente, y posteriormente a su salida devuelve valores que representan el compuesto químico sensado (gas) y la respectiva concentración del gas presente en el aire. Cada sensor está diseñado para responder a una variedad amplia de gases químicos, y en forma colectiva, responden con un patrón a diferentes gases. Y, con ello construyendo una base de datos de los patrones generados por el arreglo de sensores.

Posteriormente, proceden a realizar el prototipo de la red neuronal, esta red neuronal fue creada utilizando toolbox de Matlab, esta red neuronal fue conformada por 7 neuronas en la capa de entrada, una neurona para sensor, 3 neuronas en la capa oculta y 5 neuronas para la capa de salida. Ejecutando un entrenamiento de propagación hacia atrás. Realizando un prototipo entrenado inicialmente para la identificación de químicos comunes en el hogar. En consecuencia, obtuvieron un sistema sensor para la identificación de químicos comunes en el hogar, eficiente donde se obtiene resultados del sistema con una tasa muy baja de falsos positivos de la red neuronal, para el desarrollo óptimo de soluciones.

(Flores & Li, 2011) Presentan el diseño de una nariz electrónica con un arreglo de 6 sensores semiconductores de la marca Fígaro, los cuales tendrán la función de discriminar compuestos volátiles como, metano, butano, propano, etanol e hidrogeno. En donde el arreglo de sensores se hace indispensable para la discriminación de diferentes olores presentes en el aire, ya que esta discriminación se determina por la interpretación en conjunto de dichos sensores y no por la particularidad de cada sensor por separado. El presente proyecto se dividió en 4 factores para la construcción de la nariz electrónica.

1. Etapa de acondicionamiento de flujo de aire, esta etapa está conformada por un compresor de aire que cumple la función de desplazar el olor de las muestras desde la cámara de muestra hacia la cámara de medida, un filtro regulador de presión y un carbón activado.
2. Una cámara de muestra esta etapa está conformada por un recipiente de vidrio con una tapa de acero inoxidable, en donde se almacenará una mezcla orgánica (muestra).
3. Una cámara de medida esta etapa la conforma, un recipiente de vidrio con su respectiva tapa de acero inoxidable, una matriz de sensores y la tarjeta de adquisición de datos, donde será almacenado la muestra en estado gaseoso (olor).
4. Etapa de captura y procesamiento de datos, de esta etapa se captura la información mediante una tarjeta de adquisición de datos, Marca: National Instruments: NI USB-6009, con 14 bits y una frecuencia de muestreo de 1Hz durante diez minutos, obteniendo un total de 600 muestras por cada sensor. El proceso para la captura de las señales de cada sensor fue monitoreado y controlado por un programa implementado en el software LabVIEW Student 8.0 donde era posible observar la señal de los sensores tanto en forma individual como en colectiva.

Posteriormente aplicando un modelo de red neuronal Fuzzy ARTMAP en el software de

computación científica Matlab en su versión 7.0. para la clasificación de los compuestos mencionados anteriormente. Finalizando con un prototipo eficiente para la detección de compuestos orgánicos presentes en el aire.

Marco teórico

Arreglo de sensores.

Para la identificación de un olor tipo gaseoso en específico en la nariz electrónica depende en gran medida al tipo de sensor de gas a utilizar, ya que cada tipo de sensor responde de diferente manera, los cuales están caracterizados por su capacidad de responder ante la sensibilidad de diferentes tipos de gases. En el momento de seleccionar los sensores se debe tener en cuenta su aplicación, en este caso para la detección de gases como el propano, butano, metano, monóxido de carbono (CO) donde estos compuestos químicos en conjunto forman el hidrocarburo gas natural (Technical-data-MQgas-sensor, 2019).

Por lo que es necesario aplicar sensores conforme a estos compuestos químicos. La familia de sensores de la familia MQ brindan las características necesarias que se mencionan anteriormente referente al tipo de gas a utilizar por lo que son factibles. En el Datasheet de sensores, dependiendo de cada tipo de sensor nos proporciona unas graficas que permite obtener la concentración del gas las cuales son de gran ayuda para aplicar un entrenamiento en una RNA. Los sensores están pensados en la detección de compuestos químicos presentes en el aire y tienen la posibilidad de conectar estos sensores a un dispositivo electrónico como las plaquetas de Arduino (Technical-data-MQgas-sensor, 2019).

Arduino.

Arduino es una compañía que se dedica específicamente al desarrollo de plaquetas electrónicas y al desarrollo de software de código libre, para el desarrollo de prototipos de dispositivos digitales e interactivos los cuales pueden detectar y controlar objetos del mundo real.

Del arreglo de sensores de gas, cada sensor genera una lectura de la concentración de gas presente en el entorno, estos sensores envían esa lectura de forma codificada a través de una salida digital. Está información debe ser transmitida desde el arreglo de sensores a un computador donde la información será almacenada. Sin embargo, un computador no es capaz de entender estas lecturas de forma directa y por lo tanto no es capaz de interpretarlas, de acuerdo con esto es necesario añadir un dispositivo intermediario, el cual sea capaz de digitalizar la información como corresponda y logre comunicar al arreglo de sensores con el computador. El dispositivo debe actuar

como una interfaz entre el arreglo de sensores y el computador con el fin que este pueda entender la información y logre procesarla. El dispositivo que cumple con estos requerimientos es la plaqueta Arduino Uno (microchip ATmega328p), con especificaciones técnicas básicas: Voltaje de funcionamiento a 5V, 14 pines E/S digitales de los cuales 6 proporcionan salida PWM, 6 pines de entrada analógica y la velocidad de reloj de 16MHz. Las razones por la que emplear está plaqueta es su bajo costo y su fácil comprensión tanto de hardware y software (Diaz, 2019).

Redes neuronales artificiales (RNA o ANN).

Las redes neuronales es una de las aplicaciones que abarca el concepto de inteligencia artificial (IA) la cual es capaz de simular con componentes electrónicos los procesos de inteligencia semejantes al cerebro del ser humano, estas redes neuronales artificiales son básicamente un conjunto de nodos (llamados como neuronas) interconectados entre sí al igual que el cerebro humano con entradas y salidas, el cual contiene millones de neuronas que por medios de estímulos eléctricos se comunican entre sí, y con ello el poder “pensar y aprender”, al igual que el ser humano las redes neuronales artificiales son capaces de aprender a través de un proceso de entrenamiento configurado (Carbajar, Jimenez, Corona, & Noel, 2018).

A través de un entrenamiento de una RNA es posible generar un modelo para la detección y clasificación de diferentes olores provenientes de diferentes compuestos químicos volátiles presentes en el aire, lo cual es posible al introducir una muestra de algún gas a la entrada de un arreglo de sensores y conforme al entrenamiento de una red neuronal artificial clasifique el nivel de concentración de gas introducido y sea capaz de reconocerlo en tiempo real, actuando de forma inmediata y brinde soluciones conforme a las circunstancias

Orange.

Orange es un software totalmente gratuito que está basado en programación visual, lo cual les permite a los usuarios que no poseen grandes conocimientos de programación, realizar numerosas técnicas de Machine Learning y análisis predictivo. Orange permite crear flujos de trabajos, mediante la vinculación de widgets predefinidos por el usuario. (wiki, 2020).

Marco Legal

Este proyecto desarrollará un prototipo, que tiene como finalidad detectar los compuestos orgánicos volátiles (VOCs) presentes en el aire, en este caso: Gas Natural. Implementado conocimientos y técnicas, para la prestación de servicios de telecomunicaciones. Sin embargo, en la República de Colombia, no se han implementado normas las cuales tengan impuestos los patrones a seguir para la implementación de detectores VOCs. A pesar de ello, se han implementado normas como explica (Vanti, 2020), dichas normas imparten lineamientos generales para la instalación, distribución y acondicionamiento de gasodomésticos. De modo que garantice: “que todos los usuarios que estén conectados, en proceso de conexión o que proyecten conectarse al servicio de gas natural, cuenten los mismos derechos y deberes, las mismas condiciones de calidad, confiabilidad, continuidad” del servicio.

En efecto, las siguientes resoluciones ordenan el cumplimiento de determinadas, que aplica a pequeños y grandes consumidores, distribuidores y comercializadores de gas combustible por redes. Los cuales deben obedecer a las condiciones técnicas de los aparatos, accesorios, materiales, montaje, calidad, protección que han de reunir las conexiones para la distribución de gas. Si, por el contrario, alguna de estas medidas es incumplida se suspenderá y/o discontinuará el servicio por cualquiera de las siguientes razones: 1. “Manipulación indebida de cualquier tubería, medidor, u otra instalación del distribuidor”, 2. “Cuando la instalación interna del usuario no pase las pruebas técnicas del distribuidor” (Vanti, 2020).

De esa manera evitar que se produzcan fugas de gas en lugares cerrados y resultando en un aglomeramiento de este gas en estos tipos de lugares. Y por siguiente eliminando por completo la posibilidad provocar una explosión involuntaria y sufrir las consecuencias de inhalar las altas concentraciones de gas combustible.

1. Resolución 067 de 1995: “Por la cual se establece el Código de Distribución de Gas Combustible por Redes” (Villamizar & Barberena, 2011)
2. Resolución 1023 de 2004: “Por la cual se expide el reglamento técnico para gasodomésticos que funcionan con combustibles gaseosos, que se fabriquen o importen para ser utilizados en Colombia” (Botero, 2004)

3. Resolución 936 de 2008: “Por la cual se modifica la Resolución 1023 del 25 de mayo de 2004, por la cual se expide el Reglamento Técnico para gasodomésticos que funcionan con combustibles gaseosos, que se fabriquen o importen para ser utilizados en Colombia” (Plata, 2008)

Metodología del proyecto

Metodología cuantitativa

El enfoque cuantitativo es el método o proceso que se lleva a cabo para la recopilación, análisis y cuantificación de datos obtenidos, estos datos parten de una idea o pregunta de investigación donde se derivan variables cuantitativas. Es secuencial y probatorio, de lo cual se infiere un procedimiento dividido en etapas donde su orden es riguroso, de manera que cada etapa depende de la etapa anterior y éstas no pueden ser eludidas. Este enfoque permite analizar los datos de forma matemática y estadística, siendo concluyente en su propósito, cuantificando un problema con el fin de extraer pautas de comportamiento y probar teorías. (Hernández Sampieri, Fernandez Collado, & Baptista, 2013)

Metodología experimental

La metodología experimental es uno de los métodos de investigación cuantitativa realizada bajo un enfoque científico. Donde la investigación experimental analiza las relaciones entre una o más variables independientes y una o más variables dependientes, finalizando con la confirmación de un cambio o efecto en un experimento.

En apoyo de lo anterior, el presente proyecto aplica la metodología cuantitativa y experimental. Donde a continuación se mencionan los pasos que se dan en el desarrollo del prototipo de una nariz electrónica, de manera que se pueda identificar, analizar y cuantificar una muestra de olores gaseosos.

Pasos de la metodología:






















1. Investigaciones documentarias de las narices electrónicas
2. Ensamblar un arreglo de sensores de gas.
3. Exponer los sensores a la presencia de VOCs.
4. Adquirir datos del arreglo de sensores (huella olfativa) mediante una tarjeta de adquisición de datos (Arduino).
5. Crear una red neuronal artificial, bajo el modelo del perceptrón multicapa.
6. Realizar el entrenamiento de la red neuronal artificial basado en los datos adquiridos (huella olfativa), para la clasificar el nivel y concentración de gas natural.
7. Realizar la presentación de resultados final del prototipo.

Administración del proyecto

Cronograma de actividades

Tabla 1.

Cronograma del proyecto

Id	Modo de tarea	Nombre de tarea	Duración	Comienzo	Fin	Predecesoras	Nombres de los recursos
1		Nariz Electrónica	69 días	mar 11/08/20	vie 20/11/20		
2		Fase adquisición de componentes	2 días	mar 11/08/20	jue 13/08/20		
3		Presupuestar y adquirir componentes electrónicos en el	2 días	mar 11/08/20	jue 13/08/20		Adriana Morales;Transporte
4		Fin de fase	0 días	mar 11/08/20	mar 11/08/20		
5		Fase documentación	17 días	mar 11/08/20	vie 4/09/20		
6		Fundamentos de la nariz electronica	2 sem.	jue 13/08/20	vie 28/08/20	4;3	Adriana Morales;Libro de fundamentos[1]
7		Fundamentos de los sensores de gas	1 sem	jue 13/08/20	vie 21/08/20	3	Adriana Morales;Libro de fundamentos[1]
8		Fundamentos de las redes neuronales	3 sem.	jue 13/08/20	vie 4/09/20	3	Adriana Morales;Libro de fundamentos[1]
9		Fin de fase	0 días	mar 11/08/20	mar 11/08/20		
10		Fase diseño	27 días	mar 11/08/20	vie 18/09/20		
11		Diseño de la matriz de sensores de gas	1 sem	vie 28/08/20	vie 4/09/20	9;6;7	Adriana Morales;Libro de fundamentos[1]
12		Diseño de modelo de la red neuronal	2 sem.	vie 4/09/20	vie 18/09/20	8;6;11	Adriana Morales;Libro de fundamentos[1]
13		Fin de fase	0 días	mar 11/08/20	mar 11/08/20		
14		Fase ejecución	30 días	vie 18/09/20	lun 2/11/20		
15		Implementacion y levantamiento de información (Matriz de sensores de gas)	2 sem.	vie 18/09/20	vie 2/10/20	13;12	Adriana Morales;Arduino uno x1[1];Cable utp x metro[1];componentes
16		Entrenamiento de red neuronal artificial	3 sem.	vie 2/10/20	lun 26/10/20	12;15	Adriana Morales;Software x
17		Levantamiento de información (red neuronal artificial)	5 días	lun 26/10/20	lun 2/11/20	16	Adriana Morales;Software x hora[1];Computador
18		Fase visualización	12 días	lun 2/11/20	vie 20/11/20		
19		Levantamiento de información (nariz electronica)	6 días	lun 2/11/20	mié 11/11/20	17	Adriana Morales;Computador
20		Visualización final de protoripo	6 días	mié 11/11/20	vie 20/11/20	19	Adriana Morales;Computador
21		Fin de fase	0 días	vie 20/11/20	vie 20/11/20	20	

Presupuesto

Presupuesto de recursos humanos.

Tabla 2.

Presupuesto de recursos humanos

Perfil	Justificación	Cantidad	Duración	Valor unidad
Investigador	Personas encargadas en el desarrollo del proyecto	1	5 meses	\$ 980.657.00
Total				\$ 4.903.285.00

Nota. Autoría de Adriana Morales.

Presupuesto de equipos.

Tabla 3.

Presupuesto de equipos

Equipo	Justificación	Valor unidad
Equipo de computo	Computador personal Intel Core i5 de 1.8Ghz	\$ 1.889.400.00
Total		\$ 1.889.400.00

Nota. Autoría de Adriana Morales.

Presupuesto de software.

Tabla 4.

Presupuesto de software

Software	Justificación	Valor unidad
Programa para la adquisición, visualización y control de datos	Software libre gratuito	\$ 0.00
Total		\$ 0.00

Nota. Autoría de Adriana Morales.

Presupuesto de materiales y suministros.

Tabla 5.

Presupuesto de materiales y suministros

Materiales	Justificación	Cantidad	Valor unidad
Libro electrónico gratuito	Conocimiento de redes neuronales	1	\$ 0,00
Arduino Uno	Tarjeta de adquisición de datos	1	\$ 24.000.00
Sensor químico	Dispositivo que transforma información en una señal analítica	4	\$ 9.500.00
Modulo Ethernet	Modulo para conectarse a una red local o internet.	1	\$16.000
Componentes electrónicos básico	Dispositivo que forma parte de un circuito electrónico	4	\$ 50.00
Total			\$ 49.550.00

Nota. Autoría de Adriana Morales.

Presupuesto Total.

Tabla 6.

Presupuesto total

Ítem	Valor
Recursos humanos	\$ 4.903.285.00
Equipos	\$ 1.889.400.00
Software	\$ 0.00
Material y suministros	\$ 49.550.00
Total	\$ 6.842.235.00

Nota. Autoría de Adriana Morales.

Desarrollo del prototipo: Nariz electrónica

Capítulo I – Conceptualización de los elementos del prototipo

Fundamentos de la nariz electrónica.

La nariz electrónica se define como un instrumento electrónico de olfato artificial, el cual emula la estructura y funcionamiento de una nariz humana. Este instrumento dotado de una agrupación de componentes electrónicos simples, en este caso los sensores de gas, en conjunto de un modelo de técnicas de inteligencia artificial, cuya finalidad es analizar, discriminar y clasificar los compuestos volátiles presentes en el aire (VOCs), discriminándolos dentro de un conjunto de sustancias olorosas.

A continuación, se relacionan los diferentes factores y elementos que se conforma una nariz electrónica para la detección de Gas natural.

Gas natural. El gas natural, es un energético natural de origen fósil, compuesto por una mezcla de gases livianos. El gas natural está compuesto en gran magnitud por metano y etano, y en menor magnitud por propano, butano, pentano. Este tipo de gas se encuentra naturalmente en el subsuelo, “formado hace millones de años por la descomposición de una serie de organismos animales y vegetales, que por efectos de la presión y la temperatura transformaron lentamente el material orgánico en petróleo crudo y en gas natural” (Alcanos, 2020).

En concentraciones mínimas y espacios abiertos, “el gas natural es el combustible que menos contamina el ambiente, debido a que en su combustión no se generan gases tóxicos, cenizas y residuos”. Si bien el gas natural no es tóxico en primera instancia, en altas concentraciones puede causar problemas de salud como mareos o asfixia repentina, y en ciertas condiciones el gas que escapa hacia la atmósfera exterior puede producir mezclas inflamables que suelen encenderse en forma de llamas (Alcanos, 2020).

Sensores de gases. Los sensores de gases son dispositivos que captan la presencia de uno o varios gases presentes en el aire que son nocivos para la salud. Existen múltiples tipos de sensores de gases, en los cuales su funcionamiento es distinto y depende de la tecnología que empleen (330ohms, 2016).

Sensores catalíticos. Los sensores de difusión catalítica son los dispositivos más habituales para detectar vapores y gases combustibles. “Estos sensores se componen por dos bobinas de platino, ambas bobinas están encapsuladas en un material cerámico de alúmina”, y ambas bobinas recubiertas con dos tipos de catalizadores: uno para el elemento activo o detector, que normalmente

es de paladio (acelera la oxidación del elemento) mientras que la otra bobina que se conoce como elemento referencia o inactivo, no tiene ese material para la oxidación del gas. Su principio de funcionamiento es por la oxidación de gas vía catalítica, lo cual su operación consiste en la oxidación del gas en la superficie del elemento catalítico por medio de calor generado a partir de una tensión eléctrica que circula por la bobina (330ohms, 2016).




Figura 3. Esquemático sensor gas catalítico (Autoría propia, 2020).

Sensores infrarrojos. Los sensores infrarrojos analógicos presentan alta sensibilidad, y estabilidad para la detección de gases, su consumo de energía es bajo, y su funcionamiento se basa en emisores y receptores de luz infrarroja. Si se detecta un gas presente en el aire interfiere con la potencia de transmisión entre el emisor y el receptor, y de esa forma determinando la presencia del gas presente (330ohms, 2016).




Figura 4. Esquemático sensor gas infrarrojo (Autoría propia, 2020).

Sensores electroquímicos. Este tipo de sensores tienen dos electrodos denominados electrodo de trabajo y electrodo de referencia, y estos a su vez separados por una capa de electrolito acuoso, la cual se caracteriza por ser líquida, sólida o en forma de gel. Cuando el gas entra a la membrana del sensor “se produce una reacción de reducción-oxidación que genera una corriente eléctrica proporcional a la concentración de gas”. Este sensor tiene características básicas, como una respuesta rápida que se mantiene estable. Son fuertes y duraderos. Además, vienen calibrados de fábrica y pueden detectar concentraciones de gases relativamente muy bajas (330ohms, 2016).




Figura 5. Esquemático sensor gas electroquímico (Autoría propia, 2020).

Sensores semiconductores. Son sensores con semiconductores de óxido de metal. Su forma de funcionamiento se basa en una “película sensible al gas, esta película está compuesta principalmente por cristales de óxido-metal donde normalmente es dióxido de estaño (SnO_2), óxido de indio (InO_3) óxido de wolframio (WO_3), entre otros”. Cuando el gas entra en contacto con el sensor, provoca un cambio en la magnitud de una resistencia eléctrica. Además, cuenta con un calentador que no es más que una resistencia, el cual se encarga de elevar la temperatura y volatilizar los gases que entran en contacto con la película del sensor (330ohms, 2016).




Figura 6. Esquemático sensor gas semiconductor (Autoría propia, 2020).

Sensor de temperatura y humedad. Son sensores que miden la humedad y temperatura del aire relativo usando un sistema basado en condensadores y termistores. Estos sensores están hechos de una película generalmente de vidrio o cerámica. “El material aislante que absorbe el agua está hecho de un polímetro que toma y libera el agua basándose en la humedad relativa de la zona dada”. Esto cambia el nivel de carga de los condensadores del circuito en el cuadro eléctrico (Ecured, 2020).




Figura 7. Esquemático sensor de temperatura y humedad (Autoría propia, 2020).

Fundamentos de las redes neuronales artificiales.

Modelo biológico. La modelación de redes neuronales artificiales es un modelo matemático que se inspiró en el funcionamiento y estructura cerebro y los sistemas nerviosos del ser humano. La neurona es el elemento de mayor relevancia, ya que existen numerosos tamaños, formas y longitudes para estas. Son atributos que se consideran importantes para determinar la función y utilidad de la neurona (Hilera & Victor, 1995).

Una neurona es una célula viva que consta de un cuerpo celular más o menos esférico, el axón y varias ramas más cortas llamadas dendritas. Y se caracterizan por su capacidad de comunicarse entre sí por medio de sus conexiones llamadas sinapsis. “Las dendritas y el cuerpo celular reciben señales de entrada, el cuerpo celular las combina e integra y emite señales de salida”. El axón transporta estas señales a los terminales axónicos que se encargan de distribuir información al siguiente conjunto de neuronas, como se registra en la figura 8, (Hilera & Victor, 1995).




Figura 8. Estructura general de una neurona (Prieto, 2020).

Elementos de Redes Neuronales Artificiales. Como se mencionó las RNA son modelos que intentan reproducir el funcionamiento del cerebro humano. Una RNA consta de un conjunto de neuronas interconectadas entre sí enviando información entre ellas a partir de sus conexiones de entrada y salida. Como tal modelo realiza una simplificación, averiguando cuales son los elementos relevantes del sistema, bien sea por la cantidad de información que se dispone es excesiva o bien sea redundante. (Hilera & Victor, 1995)

Los elementos básicos son:

1. Conjuntos de neuronas de procesamiento.
2. Conexiones entre neuronas y un peso sináptico asociado a cada neurona.
3. Funciones de salida o activación para cada neurona.

En consecuencia, se describirán los conceptos básicos de los distintos elementos de un modelo de RNA.

Conjunto de neuronas de procesamiento. Consta de N unidades (neuronas) ordenadas y unidas arbitrariamente, estas unidades están unidas mediante conexiones, y su trabajo es simple y único el cual consiste en recibir las entradas de las unidades vecinas y calcular un valor de salida, el cual es enviado a todas las neuronas restantes. Estas neuronas se pueden caracterizar en tres tipos: neuronas de entradas, salidas u ocultas (Hilera & Victor, 1995).

Las neuronas de entrada reciben señales desde el entorno exterior, las neuronas de salida que son a la vez salidas de la red envían la señal fuera del sistema de red neuronal, y las neuronas ocultas son aquellas cuyas entradas y salidas se encuentran dentro del sistema de red, y por ende no tienen contacto con exterior.

Conexiones entre neuronas. Cada conexión de la RNA se le es asignado un peso sináptico de valor numérico, estos pesos sinápticos son los encargados de suministrar conocimiento a la red neuronal. Una neurona recibe un conjunto de señales de entrada que le dan información del estado de activación de todas las neuronas con las que se encuentra conectada. La conexión que hay entre la neurona i y la neurona j esta ponderada por un peso sináptico W_{ij} . Este peso conforma el patrón de memoria a largo plazo, y el entrenamiento de aprendizaje usualmente se realiza con la modificación de tales pesos (W_{ij}), (Hilera & Victor, 1995).

Funciones de salida o activación. Como se ha mencionado cada neurona transmite señales de entrada a otras neuronas que estén conectadas con su salida. Cada neurona se asocia con una función de salida $f_i(a_i(t))$, la cual transforma el estado actual de activación $a_i(t)$ en una señal de salida $y_i(t)$, es decir:

$$y_i(t) = f_i(a_i(t)) \quad (1)$$

Donde f_i es la función identidad o transferencia.

Existen variedad de funciones de transferencia típicas que determinan distintos tipos de neuronas, y se describirá cada una de ellas.

- **Función escalón**

La función de activación escalón, determina si la suma de las entradas es mayor o igual que el umbral de la neurona, si la activación es igual a uno (1), si por lo contrario es menor que el umbral, la activación es igual a 0 a -1. Como se muestra en la siguiente figura 9 (Ponce, 2010, pág. 200).




Figura 9. Función escalón (Ponce, 2010).

- **Función lineal y mixta**

La función lineal o de identidad de activación, en las neuronas con función mixta, determina si la suma de las señales de entrada es menor a que un límite inferior, la función se define como 0 (0-1), si por el contrario la suma es igual o mayor que el límite superior, la activación es 1. Pero si la suma de la entrada está definida entre los dos límites, la activación será 1, o si la suma se encuentra entre ambos límites, superior e inferior, entonces la activación se define como una función lineal de la suma de las señales de entrada, como se muestra en la siguiente figura 10 (Ponce, 2010, pág. 200).




Figura 10. Función lineal y mixta (Ponce, 2010).

- **Función sigmoideal**

La función de activación sigmoideal determina si el valor dado por la función es cercano a los valores asintóticos. de acuerdo con esto, el valor de la salida está comprendida en una zona alta o baja de la sigmoide. Para la función sigmoideal su derivada siempre es positiva y cercana a cero

para los valores grandes positivos o negativos. Además, que cuando la pendiente es elevada la función tiende a ser una función escalón, y cuando toma su valor máximo, ósea $x=0$, de esa forma utilizando reglas de aprendizaje definidas para la función. De esta forma se puede ver en la siguiente figura 11 (Ponce, 2010, pág. 201).




Figura 11. Función sigmoideal (Ponce, 2010).

- **Función tangente hiperbólica**

La función de activación tangente hiperbólica se emplea cuando se evidencia una variación suave de valores positivos y negativos de la señal a clasificar. De esta forma se evidencia en la siguiente figura 12. (Ponce, 2010, pág. 201)




Figura 12. Función hiperbólica tangente (Ponce, 2010).

- **Función de unidad lineal rectificadora (ReLU).**

“Esta función transforma los valores introducidos anulando los valores negativos y dejando los positivos tal y como entran” (Alvarado, 2020).




Figura 13. Función ReLU (Alvarado, 2020).

Estructura de una red neuronal. Después de analizar los componentes más importantes de una RNA, es necesario comprender como está organizada dicha red, la estructura de una RNA se clasifica en función de:

- **Numero de nivel o capas**

Las neuronas dentro de una red se distribuyen en niveles o capas, con un número determinado de dichas neuronas para cada una de ellas. Se pueden clasificar en tres tipos de niveles: de entrada, ocultas y de salida (Hilera & Victor, 1995).

- **Patrones de conexión**

La conexión entre las neuronas de una RNA se relaciona con la forma en que las salidas de las neuronas están conectadas de modo que se convierten en las entradas de otras neuronas. Las señales de salida de una neurona puede ser la entrada a otra neurona o incluso puede ser una entrada de sí mismo.

Cuando ninguna salida de las neuronas es entrada de otras neuronas del mismo nivel o de niveles previos, la red se describe como red de conexión hacia delante. O si es, por el contrario, las salidas se conectan como entradas de neuronas de niveles anteriores o del mismo nivel, incluyéndose ellas mismas se describe como red de conexión hacia atrás (Hilera & Victor, 1995).

Características de las redes neuronales. Hay parámetros que definen una RNA, como la topología de red, entrenamiento de aprendizaje y el tipo de conexión entre la información para la capa de entrada y de salida (Hilera & Victor, 1995).

Tipología de las redes neuronales. La topología o estructura de las RNA consiste en la organización de las neuronas y disposición de cada una en la red, de esa manera formando niveles o capas de neuronas más o menos distanciadas de la salida y de la salida. Cuando se realiza una clasificación de las redes en términos de topológicos se suele diferenciar entre las redes de una sola capa o nivel de neuronas y las redes con múltiples niveles o capas (Hilera & Victor, 1995).

- **Redes monocapa o una capa.**

En las redes monocapa solo la constituye una única neurona de la red. Este tipo de redes presentan las entradas directamente conectadas a las salidas mediante pesos, donde las salidas no interactúan y de esa forma una red con N salidas puede ser analizada como N redes separada (Hilera & Victor, 1995).

- **Redes multicapas**

Las redes multicapa son constituidas por conjuntos de neuronas agrupadas en varios niveles o

capas intermedias entre la entrada de la red y la salida.

- **Redes con conexión hacia adelante.**

En las redes con conexiones hacia adelante, las señales de entrada se multiplican hacia adelante pasando por todos los niveles o capas de la red. Por ende, la salida de la neuronas de una capa i aplica se aplica a la entrada de neuronas de capas $i-1$, y de esa forma ninguna salida de una neurona se conecta a su propia entrada (Hilera & Victor, 1995).

- **Redes con conexión recurrentes.**

Este tipo de redes poseen conexiones de retroalimentación, lo que puede derivarse en un proceso de evolución hacia un estado estable en el que no haya cambios en el estado de activación de las neuronas. (Hilera & Victor, 1995)

Mecanismo de aprendizaje. Al proceso de entrenamiento de una red neuronal se denomina entrenamiento de aprendizaje, del cual se busca obtener unas salidas deseadas, respecto a los datos de entradas. Para que una neurona sea capaz de aprender, se realizan modificaciones en los pesos asignados de las entradas. Sin embargo, un aspecto fundamental respecto al entrenamiento de aprendizaje en las redes es saber cómo se modifican los valores de los pesos. Una forma de realizar estas modificaciones es estableciendo pesos conocidos con anterioridad. Sin embargo, existe otro método el cual consta de técnicas de retroalimentación y modelos de aprendizaje que consiste en cambiar los pesos hasta encontrar los adecuados (Ponce, 2010, pág. 203). A partir de ello se suele considerar dos tipos de reglas, las que responden a lo que habitualmente se conoce como:

1. Supervisado o asociativo, en este método se introducen entradas que corresponden a determinadas salidas. (Ponce, 2010, pág. 203)
2. No supervisado o autoorganizado, este método se enfoca en encontrar características estadísticas entre agrupamientos de patrones en las entradas. (Ponce, 2010, pág. 203)

Por ello usualmente se clasifica el tipo de aprendizaje que se realizan las redes neuronales. De esta forma se puede distinguir:

- **Redes neuronales con aprendizaje supervisado**

El aprendizaje supervisado se caracteriza porque entrenamiento que realiza la red neuronal consta de la intervención de un supervisor externo que determina la respuesta que debería generar la red a partir de una entrada determinada.

- **Redes neuronales con aprendizaje no supervisado**

El aprendizaje no supervisado no requiere de la intervención externa de un supervisor para

ajustar los valores de los pesos sinápticos que hay entre las conexiones neuronas. De esta manera la red no recibe información verificación del entorno exterior indicándole que la salida generada por la red es o no correcta (Hilera & Victor, 1995).

Redes de retropropagación (Backpropagation). La propagación hacia atrás de errores o retropropagación, se conoce como un entrenamiento supervisado que es empleado en redes multicapa, donde a partir de un error generado en la red se ajusta el valor de los pesos sinápticos de manera que se pueda minimizar los más posible dicho error generado (Ponce, 2010, pág. 225).

- **Redes heteroasociativas**

Las redes heteroasociativas reúne toda la información de entrada y la relaciona con información de salida de la red, se precisa necesario tener para este tipo de red tener al menos dos niveles o capas, una para captar y retener la información de entrada y otra para mantener la salida con la información asociada (Hilera & Victor, 1995).

- **Redes autoasociativas**

Las redes autoasociativas relaciona la información de entrada con el modelo más parecido de los modelos almacenados conocidos por la red anteriormente. Para este tipo de redes pueden ser implementadas con un solo nivel o capa de neuronas. De esta manera se puede retener la información inicial presentada a la entrada y terminara representando la información autoasociada (Hilera & Victor, 1995).

Redes neuronales con conexiones hacia adelante. A continuación, se describe algunos tipos de RNA con conexiones hacia adelante, donde tales redes se caracterizan por tener una arquitectura en niéveles y las conexiones entre neuronas es estrictamente hacia adelante. Estas redes utilizan entrenamiento de aprendizaje supervisado, estas redes se consideran buenos clasificadores de modelos lineales y no lineales. Este tipo de redes incluye el perceptrón y perceptrón multicapa.

El perceptrón. El perceptrón se considera como el primer tipo de red neuronal artificial desarrollado por Rosenblatt en el año 1958. En los años 60 despertó gran interés debido a su capacidad para aprender a reconocer patrones sencillos. Es un tipo de red neuronal simple, y se compone de una capa de entrada y una neurona o capa de procesamiento, la cual ejecuta una función de activación dotada por el carácter f . Su funcionamiento básicamente consiste en una suma de señales de entrada multiplicadas por una serie de valores de los pesos (w) sinápticos asignados a cada entrada, de forma que se denota en la siguiente ecuación, $z = x_1 \cdot w_1 + x_2 w_2 + \dots + x_p w_p$, donde a dicha ponderación se le aplicara la función de activación, donde al final se produce una salida dotada con el carácter y , la cual consta de la función de activación evaluada en el ponderamiento $f(z)$ (Ponce, 2010, pág. 8).

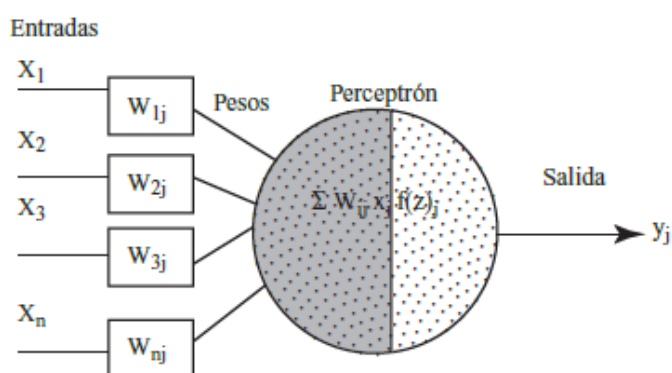


Figura 14. Estructura de la red neuronal perceptrón monocapa (Ponce, 2010).

El perceptrón es la forma más simple usada para la clasificación de un tipo especial de patrones linealmente separables. Una fase de esta red es la de aprendizaje, donde esta red se entrena y aprende, comparando los parámetros de entrada con los parámetros preestablecidos de salida deseada, que a la salida se detecta un cero (0) o un (1), si la comparación de los parámetros, a la salida se detecta que el patrón preestablecido es mayor será un 1, de lo contrario su salida será 0, (Ponce, 2010, pág. 8).

El perceptrón multicapa. La red neuronal perceptrón surge de la generalización de la red neuronal perceptrón monocapa. Es uno de los primeros modelos de red neuronal en presentar un aprendizaje supervisado, es una red de tipo: conexiones hacia delante. Empleando redes de varias capas intermedias entre la capa de entrada y la capa de salida. Este modelo de red neuronal emplea funciones de activación de forma binaria. Esta red neuronal actúa como un clasificador, que tiene como función la clasificación de patrones que no son linealmente separables (Ponce, 2010, pág.

225).

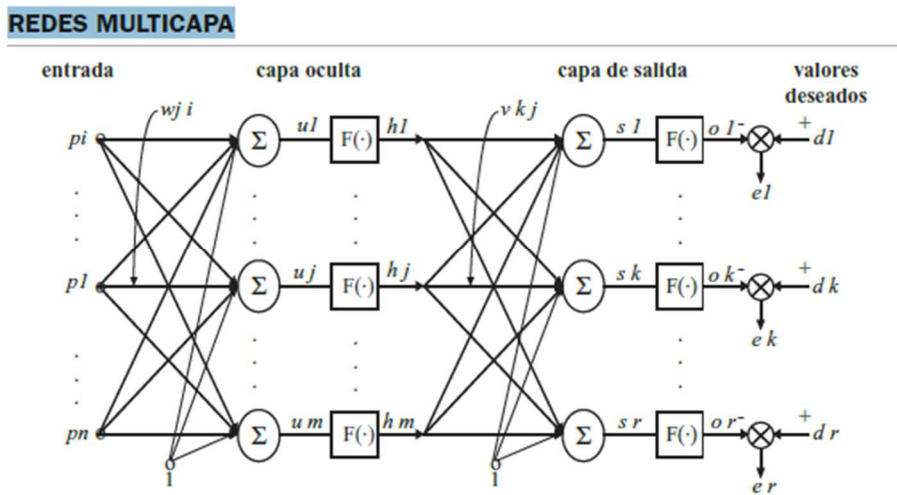


Figura 15. Estructura de la red neuronal perceptrón multicapa (Ponce, 2010).

- **Regla de aprendizaje del perceptrón**

El algoritmo de aprendizaje del perceptrón es de tipo supervisado, por ende, requiere que sus resultados sean verificados por un agente externo y se realicen modificaciones de los pesos del sistema si fuese necesario. Como se ha mencionado los valores de los pesos determinan el funcionamiento de la red, valores que pueden fijarse o adaptarse utilizando diferentes algoritmos de entrenamiento de la red (Ponce, 2010).

Capítulo II – Ejecución del prototipo

Arreglo de sensores de gas.

De acuerdo con la investigación respecto a los tipos de sensores de gas que dispone el mercado en Colombia, se analiza y se escoge la opción de sensores semiconductores. Dadas sus propiedades se escoge sensores basados en esta tecnología, y de esa manera se selecciona los sensores de la serie MQ. Los sensores de gas de la serie MQ son dispositivos analógicos diseñados para detectar la presencia de distintos compuestos volátiles (VOCs) presentes en el aire dentro de una determinada área. En la actualidad existe una gran variedad de sensores semiconductores de esta serie, en los cuales, cada modelo está diseñado para detectar una o más sustancias, pensadas para un uso específico, como lo es la detección de gases inflamables y la calidad del aire. Y con relación a esta información, se infiere que, para la realización de este proyecto es necesario usar tres sensores, relacionados con la referencia MQ2, MQ3 y MQ6 donde cada sensor detectara un derivado del gas natural. A continuación, se presenta la relación entre la referencia de cada sensor,

características y la sensibilidad al gas al que cada sensor estará configurado para detectar.

Tabla 7.

Set de sensores MQ y su respectiva sensibilidad

Referencia Sensor	Tensión de alimentación	Potencia máxima	Intensidad máxima	Alta sensibilidad
MQ-2	5V	900mW	180mW	Gas H2 Y CO
MQ-3	5V	900mW	180mW	Gas Metano, Alcohol y etanol
MQ-6	5V	900mW	180mW	Gas LPG

Nota. Autoría de Adriana Morales.

El principio de funcionamiento de estos sensores es el siguiente: Este dispositivo que internamente usa un calentador y una resistencia en conjunto donde aquella resistencia varía de acuerdo con la concentración de gas presente, por otra parte, el sensor necesita una resistencia (RL) para cerrar el circuito y de esta manera poder hacer un divisor de tensión para ser leído desde la tarjeta Arduino. Esta resistencia del sensor y calentador se conocen como bobina-calentador (heater coil) y posee un recubrimiento hecho de un compuesto o sustancia que es sensible a la presencia de un determinado compuesto de gas. En la mayoría de los casos los compuestos que se usan para recubrir la bobina-calentador es el dióxido de estaño y dióxido de aluminio (capa sensible). La bobina-calentador elevan la temperatura, a medida que se detecte un gas y con ello se consigue que los gases se evaporen cuando entren en contacto con esta, evitando saturaciones y retornando a valores correctos respecto a la concentración de gas. Seguidamente se presenta un gráfico de estos sensores de gas a utilizar. Ver figura 16.




Figura 16. Ilustrativo sensor de gas serie MQ (Circuitarte, 2020).

Cada sensor de gas que forma parte del arreglo del sistema de sensado obtiene lecturas acorde a la proporción y concentración del gas detectado. Estas lecturas son enviadas a un computador desde el arreglo de sensores. Sin embargo, es necesario añadir un dispositivo intermediario el cual tenga la capacidad de comunicar el arreglo de sensores con el computador y tratar la información

deseada de la forma que corresponda.

De acuerdo con la información proporcionada acerca de los sensores utilizados y acorde a las características a los que estos funcionan. Se opta por seleccionar la tarjeta electrónica de Arduino la versión Uno, la cual posee 6 entradas analógicas y 14 entradas digitales, es económico, versátil y de fácil funcionamiento. Ver figura 17.




Figura 17. Tarjeta electrónica Arduino Uno (Circuitarte, 2020).

Una vez seleccionados los elementos y sensores que conformara la nariz electrónica y comprendida la información acerca del funcionamiento de los sensores de la serie MQ, se procede a diseñar el arreglo de sensores, el cual consta de 3 sensores de gas y un único sensor para medir temperatura y humedad, como se muestra en las figuras 18 y 19.

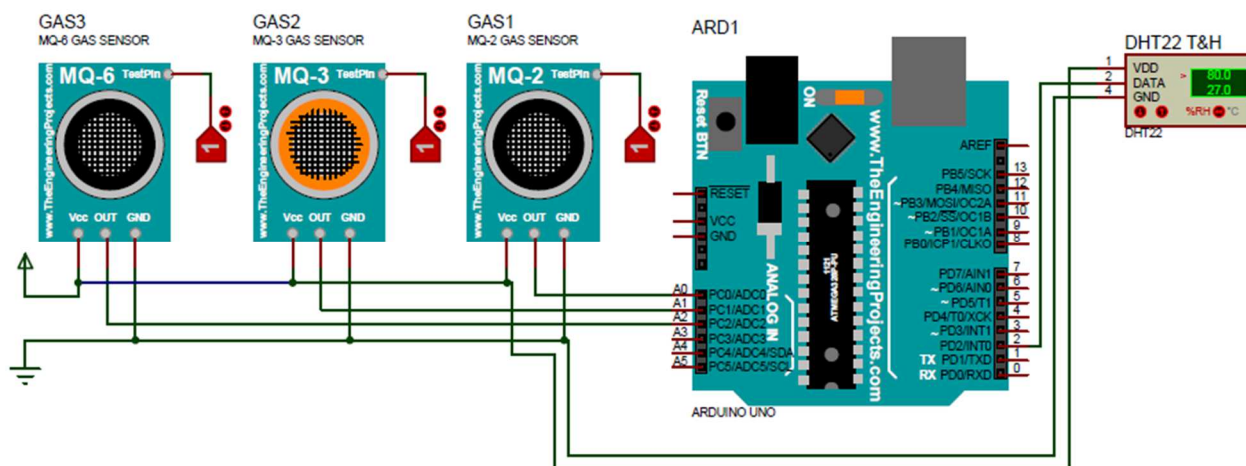


Figura 18. Bosquejo del arreglo de sensores (Autoría propia, 2020).




Figura 19. Implementación circuito de arreglo de sensores (Autoría propia, 2020).

Como se ha mencionado en repetidas ocasiones, este prototipo tiene como finalidad detectar la presencia de gas natural presente en ambientes residenciales, sin embargo, se consideró la opción de no realizar la determinación del gas natural en específico debido a que en la actualidad todavía se encuentra un sin número de personas residentes de hogares que no cuentan con el servicio de gas natural, donde dichos residentes su forma de realizar actividades con el uso de gasodomésticos es a través del uso de otras técnicas de generación de gas, como lo son cilindros de gas que solo proporcionan gas propano o butano, debido a esto se opta por realizar la determinación de 3 gases en específico, los gases a detectar son el gas metano, gas butano y propano y el monóxido de carbono. Estos gases en conjunto forman la mayor parte del gas natural, y de esta forma cumpliendo con los requisitos estipulados para la ejecución de este proyecto, beneficiando tanto a los usuarios que dispongan o no del servicio de gas natural.

De acuerdo con esto, se menciona la siguiente relación, donde acorde a la selección de los sensores, cada uno detectara un gas específico. De la siguiente manera donde se habían seleccionaron tres sensores de gas, ahora el sensor MQ2 se selecciona para la detección únicamente del gas monóxido de carbono, el sensor MQ3 se selecciona para la detección únicamente del gas metano y, por último, el sensor MQ6 se selecciona para la detección únicamente del gas propano y butano. Y, por consiguiente, y acorde a esta información se procede a realizar la correspondiente calibración de los sensores.

Calibración de los sensores MQ.

El fabricante de este tipo de sensores recomienda realizar una calibración a los sensores antes de su uso continuo, con el fin de obtener medidas acordes a la realidad del gas a detectar, en específico de los sensores MQ2, MQ3 y MQ6 implementados en este proyecto. La calibración de estos sensores obedece a un procedimiento que consta de los pasos que se presentan a continuación.

1. Realizar un precalentamiento del sensor durante 24 horas, según lo indica el datasheet.
2. Investigar el valor correspondiente de la resistencia RL, según lo indica cada sensor en la parte posterior de este (en este caso 1KΩ).




Figura 20. Indicativo de RL(1KΩ) en el sensor MQ (Circuitarte, 2020).

3. Medir el valor correspondiente de la resistencia del sensor (RS), donde este valor lo conseguimos obedeciendo a la siguiente ecuación.

$$\frac{RS}{RL} = \frac{V - VS}{VS} \quad (2)$$

Donde V es igual a voltaje y VS es igual a voltaje del sensor.

4. Medir el valor R0 en aire ambiente.

Una vez se obtenga el valor de RS, se procede a calcular el valor de R0.

Teniendo en cuenta que podemos calcular R0 con la siguiente ecuación.

$$\frac{RS}{R0} = \text{Proporción de gas} \quad (3)$$

5. Calcular el valor correspondiente de la relación RS/R0 en una concentración de gas conocida (aire ambiente), de esa forma verificando que el sensor este tomando lecturas correctas.

De acuerdo con esta información, se procede a realizar la calibración de los sensores de gas, y para esto nos apoyamos en las curvas características a la sensibilidad de gas, que nos proporciona cada datasheet de cada referencia de sensor.




Figura 21. Curva características MQ2 (hwsensor, 2020).




Figura 22. Curva características MQ3 (hwsensor, 2020).




Figura 23. Curva características MQ6 (hwsensor, 2020).

De acuerdo con la información que nos proporciona la hoja de datos, a la curva de sensibilidad de gas, se puede extraer la siguiente información para realizar la calibración de los sensores. El valor $RS/R0$ correspondiente a línea del aire ambiente (limpio), donde se obtiene que para el sensor MQ2, la proporción es de 9.98, para el MQ3, la proporción es igual a 66.48, y para el MQ6, la proporción es igual a 9.98. y con estos datos, solo falta despejar y remplazar en las fórmulas correspondientes.

La calibración de los sensores MQ se realizó por medio de programación, bajo el uso de la tarjeta de adquisición de datos y el IDE de Arduino. Para de esa forma obtener los valores de salida acorde a los valores de cada sensor a la presencia del gas. Desarrollando toda la calibración de los sensores en ambientes totalmente limpios a la presencia de algún gas presente en el aire. Como se presenta en las siguientes imágenes.

```

void loop() {
  for(int i=0; i<100; i++)
  {
    mq2_valor= mq2_valor + analogRead (A0); // Lectura pin analogico A0
    delay(10);
    mq3_valor= mq3_valor + analogRead (A1); // Lectura pin analogico A1
    delay(10);
    mq6_valor= mq6_valor + analogRead (A2); // Lectura pin analogico A2
    delay(10);
  }
  mq2_valor= mq2_valor/100.0;
  mq3_valor= mq3_valor/100.0;
  mq6_valor= mq6_valor/100.0;

  mq2_volt= mq2_valor/1024*5.0; //Conversión valor mq2 analogico a voltaje (MQ2)
  mq2_rs= mq2_rl*(5.0-mq2_volt)/mq2_volt; //Cálculo valor resistencia RS (MQ2)
  mq2_r0= mq2_rs/9.98; //Cálculo valor R0 (MQ2)aire limpio

  mq3_volt= mq3_valor/1024*5.0; //Conversión valor mq2 analogico a voltaje (MQ3)
  mq3_rs= mq3_rl*(5.0-mq3_volt)/mq3_volt; //Cálculo valor resistencia RS (MQ3)
  mq3_r0= mq3_rs/66.48; //Cálculo valor R0 (MQ3)aire limpio

  mq6_volt= mq6_valor/1024*5.0; //Conversión valor mq2 analogico a voltaje (MQ6)
  mq6_rs= mq6_rl*(5.0-mq6_volt)/mq6_volt; //Cálculo valor resistencia RS (MQ6)
  mq6_r0= mq6_rs/9.98; //Cálculo valor R0 (MQ3)aire limpio

```

Figura 24. Sketch IDE Arduino, cálculo RS y R0 en aire ambiente (Autoría propia, 2020).

```

Serial.print("mq2_volt = ");
Serial.print(mq2_volt);
Serial.print("V ");
Serial.print("mq2_r0 = ");
Serial.println(mq2_r0);
Serial.print("mq3_volt = ");
Serial.print(mq3_volt);
Serial.print("V ");
Serial.print("mq3_r0 = ");
Serial.println(mq3_r0);
Serial.print("mq6_volt = ");
Serial.print(mq6_volt);
Serial.print("V ");
Serial.print("mq6_r0 = ");
Serial.println(mq6_r0);
delay (10000);

```

Figura 25. Impresión calculo R0 en aire ambiente (Autoría propia, 2020).

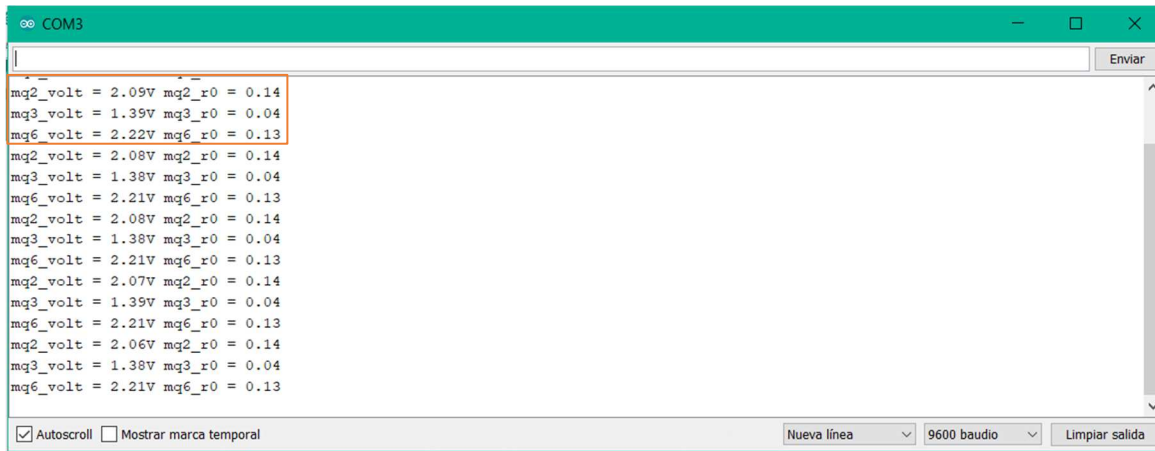


Figura 26. Respuesta monitor serie, resultados del cálculo R0 (Autoría propia, 2020).

```

float mq2_volt; float mq2_rs; float MQ2RSR0 ; float mq2_valor;
float mq3_volt; float mq3_rs; float MQ3RSR0 ; float mq3_valor;
float mq6_volt; float mq6_rs; float MQ6RSR0 ; float mq6_valor;

void setup() {
  Serial.begin(9600);
}

void loop() {

  mq2_valor = analogRead(A0);           // Lectura pin analogico A0
  mq2_volt = mq2_valor/1024*5.0;
  mq2_rs = (5.0-mq2_volt)/mq2_valor;
  mq3_valor = analogRead(A1);           // Lectura pin analogico A1
  mq3_volt = mq3_valor/1024*5.0;
  mq3_rs = (5.0-mq3_volt)/mq3_valor;
  mq6_valor = analogRead(A2);           // Lectura pin analogico A2
  mq6_volt = mq6_valor/1024*5.0;
  mq6_rs = (5.0-mq6_volt)/mq6_valor;

  MQ2RSR0 = mq2_rs/0.12; // Proporción = RS/R0 aire ambiente
                        // (reemplazar R0) resultado del sketch anterior
  MQ3RSR0 = mq3_rs/0.05; // Proporción = RS/R0 aire ambiente
                        // (reemplazar R0) resultado del sketch anterior
  MQ6RSR0 = mq6_rs/0.15; // Proporción = RS/R0 aire ambiente
                        // (reemplazar R0) resultado del sketch anterior

```

Figura 27. Proporción del aire ambiente actual (Autoría propia, 2020).

```

Serial.print("mq2_volt = ");
Serial.print(mq2_volt);
Serial.print(" ");
Serial.print("mq2_rs = ");
Serial.print(mq2_rs);
Serial.print(" ");
Serial.print("Rs/R0 = ");
Serial.println("MQ2RSR0");
Serial.print("mq3_volt = ");
Serial.print(mq3_volt);
Serial.print(" ");
Serial.print("mq3_rs = ");
Serial.print(mq3_rs);
Serial.print(" ");
Serial.print("Rs/R0 = ");
Serial.println("MQ3RSR0");
Serial.print("mq6_volt = ");
Serial.print(mq6_volt);
Serial.print(" ");
Serial.print("mq6_rs = ");
Serial.print(mq6_rs);
Serial.print(" ");
Serial.print("Rs/R0 = ");
Serial.println("MQ6RSR0");
Serial.print(" ");
delay(10000);

```

Figura 28. Impresión de la proporción en aire ambiente (Autoría propia, 2020).

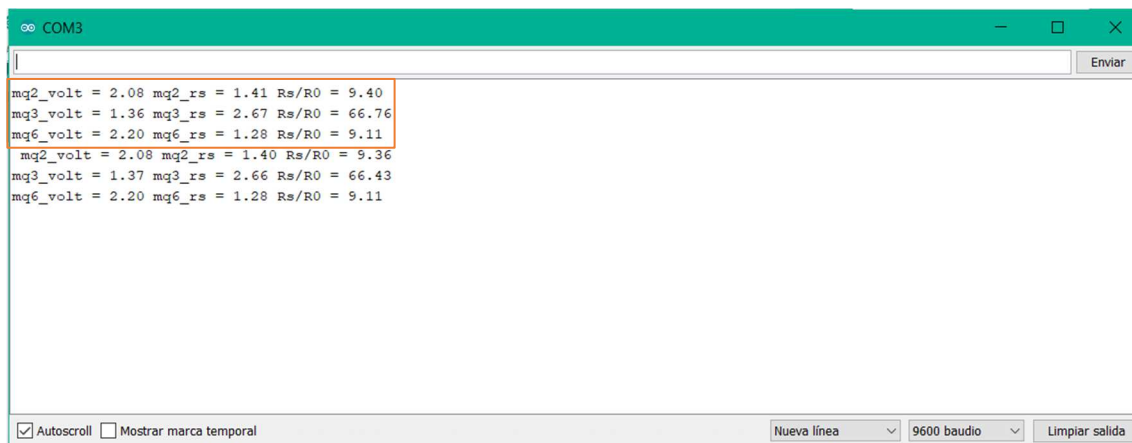


Figura 29. Respuesta monitor serie, resultados para la proporción de aire ambiente (Autoría propia, 2020).

De esta forma verificando que los sensores de gas arrojan lecturas correctas a cerca de la proporción de gas presente en el aire, en este caso calibrados de forma correcta para el aire limpio ambiente.

Ahora partiendo del hecho que mediante la calibración para cada sensor se obtuvo, la correspondiente proporción de gas presente en el ambiente, sin embargo, estos sensores no nos arrojan de forma directa lecturas de acuerdo con la concentración de gas, se procede a realizar la correspondiente programación en Arduino, para obtener de acuerdo con la proporción de gas la concentración de dicho gas en partes por millón (PPM), ver figura 30.

Si nos dirigimos a las figuras (21, 22 y 23), se relacionan las gráficas de las curvas características para cada tipo de gas capaz de detectar el sensor, esta grafica dispone de una escala logarítmica tanto para el eje x tanto para el eje y. Conforme a ello, se procede a aproximar la recta que aproxima a la concentración de gas, para el sensor MQ2= CO, para el sensor MQ3= metano, y para el sensor MQ6= GLP. Acorde a esto, nos apoyamos en la siguiente ecuación la cual nos permite aproximar la recta y obtener la concentración de gas para cada sensor.

$$PPM = \text{intercepto} \frac{RS \text{ pendiente}}{R0} \quad (4)$$

Donde para cada sensor se definió así:

MQ2: intercepto: 29.612, pendiente: -2.941.

MQ3: intercepto: 40.500, pendiente: -20.8.

MQ6: intercepto: 1011.2, pendiente: -2.385.

```
float x1= 29.612 * MQ2RSR0;
float x2= 40.500 * MQ3RSR0;
float x3= 1011.2 * MQ6RSR0;

MQ2PPM = pow (x1, -2.941);
MQ3PPM = pow (x2, -20.8);
MQ6PPM = pow (x3, -2.385);
```

Figura 30. Cálculo para la concentración de gas PPM (Autoría propia, 2020).

Además, se considera pertinente añadir al arreglo de sensores un sensor capaz de realizar mediciones respecto a la temperatura y humedad relativas del aire sensado, ya que los sensores de la serie MQ son sensibles a la variación de la temperatura y humedad, lo cual puede entorpecer su óptimo funcionamiento. Con el fin de verificar las posibles variaciones que se presente con respecto

a estas magnitudes, tanto a la hora de realizar su calibración como después de esta, se selecciona un único sensor que sea capaz de tomar medidas de la temperatura y humedad ambientales de forma simultánea. El sensor DHT22, es un sensor digital de temperatura y humedad relativa, este sensor es de bajo costo y su nivel de rendimiento es alto. Integra un sensor capacitivo de humedad y un termistor para medir el aire circundante, lo cual permite realizar la medición simultanea de estas dos magnitudes.




Figura 31. Ilustrativo sensor DHT22 (Circuitarte, 2020).

```
#include <DHT.h>
#include <DHT_U.h>

int sensor_th=3; int temperatura; int humedad;

DHT dht (sensor_th, DHT22);

void setup() {
  Serial.begin(9600);
  dht.begin(); // Inicialización del sensor
}

void loop() {

  temperatura= dht.readTemperature(); // Temperatura °C
  humedad= dht.readHumidity(); // Humedad %

  Serial.print("Temperatura = ");
  Serial.print(temperatura);
  Serial.println("°C");
  Serial.print("Humedad = ");
  Serial.print(humedad);
  Serial.println("%");
  Serial.println(" ");
  delay(10000);
}
```

Figura 32. Configuración del sensor DHT22 (Autoría propia, 2020).

Pruebas funcionamiento de sensores.

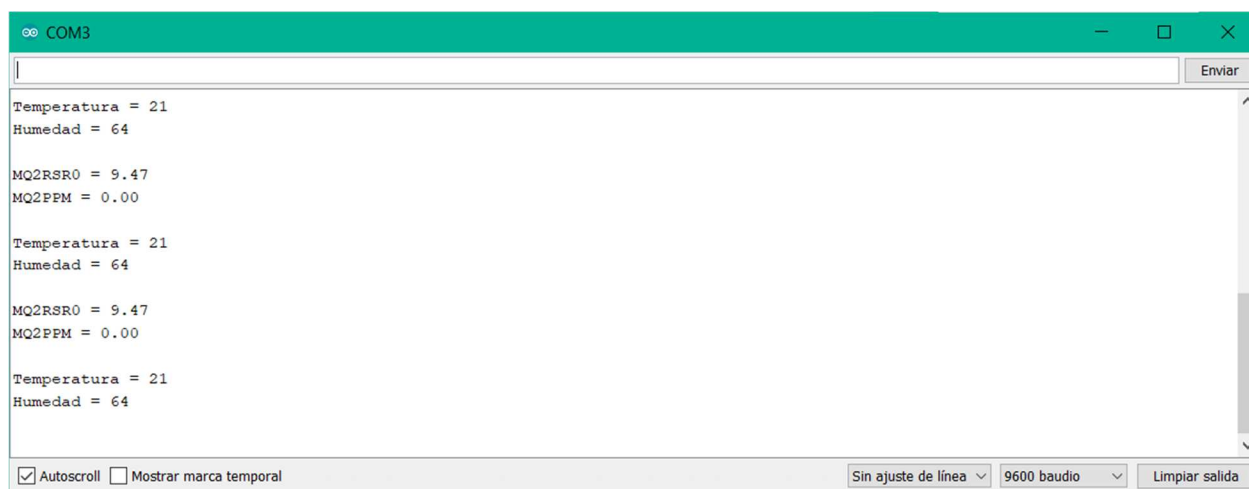
A continuación, se relaciona la respuesta que se obtuvo de los sensores de gas a la exposición del gas a detectar, conforme a la calibración que se realizó para cada sensor.

Donde para cada sensor que conforma el arreglo de sensores, se realizó el siguiente procedimiento de forma individual.

- Se adecuó un sitio neutro, fuera de cualquier contaminación ambiental.
- Se ubicó el arreglo de sensores en el lugar neutro, para posteriormente a la exposición de los diferentes gases.
- Se expuso cada sensor a la presencia de los diferentes gases a detectar, a la vez que se tomaban lecturas de humedad y temperatura.

Para el sensor de gas MQ2

En primer lugar, se realizó pruebas del sensor sin la exposición de gas, y posteriormente se realizó pruebas con exposición de gas. Donde para este sensor se obtuvieron las siguientes lecturas, acorde a la proporción y concentración de gas, además se toman medidas acorde a la temperatura y humedad relativas del ambiente.



The screenshot shows a serial monitor window titled 'COM3' with a green header. The main area displays three identical lines of sensor data. The data for each line is: Temperatura = 21, Humedad = 64, MQ2RSR0 = 9.47, and MQ2PPM = 0.00. At the bottom, there are control options: 'Autoscroll' (checked), 'Mostrar marca temporal' (unchecked), 'Sin ajuste de línea' (dropdown), '9600 baudio' (dropdown), and 'Limpiar salida' (button).

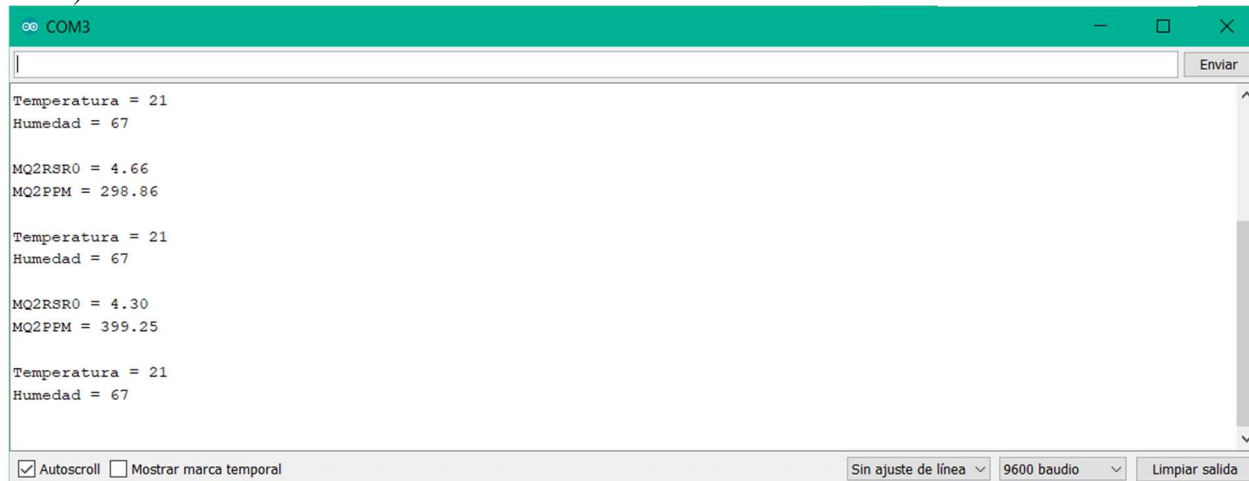
```
COM3
Temperatura = 21
Humedad = 64
MQ2RSR0 = 9.47
MQ2PPM = 0.00

Temperatura = 21
Humedad = 64
MQ2RSR0 = 9.47
MQ2PPM = 0.00

Temperatura = 21
Humedad = 64
MQ2RSR0 = 9.47
MQ2PPM = 0.00

Autoscroll [x]  Mostrar marca temporal [ ]  Sin ajuste de línea [v]  9600 baudio [v]  Limpiar salida [b]
```

Figura 33. Respuesta del sensor MQ2 sin presencia de gas monóxido de carbono (CO) (Autoría propia, 2020).



The screenshot shows a serial monitor window titled 'COM3' with a green header. The main area displays three identical lines of sensor data. The data for each line is: Temperatura = 21, Humedad = 67, MQ2RSR0 = 4.66, and MQ2PPM = 298.86. At the bottom, there are control options: 'Autoscroll' (checked), 'Mostrar marca temporal' (unchecked), 'Sin ajuste de línea' (dropdown), '9600 baudio' (dropdown), and 'Limpiar salida' (button).

```
COM3
Temperatura = 21
Humedad = 67
MQ2RSR0 = 4.66
MQ2PPM = 298.86

Temperatura = 21
Humedad = 67
MQ2RSR0 = 4.30
MQ2PPM = 399.25

Temperatura = 21
Humedad = 67
MQ2RSR0 = 4.30
MQ2PPM = 399.25

Autoscroll [x]  Mostrar marca temporal [ ]  Sin ajuste de línea [v]  9600 baudio [v]  Limpiar salida [b]
```

Figura 34. Respuesta del sensor MQ2 con presencia de gas monóxido de carbono (CO) (Autoría propia, 2020).

Para el sensor de gas MQ3

En primer lugar, se realizó pruebas del sensor sin la exposición de gas, y posteriormente se realizó pruebas con exposición de gas. Donde para este sensor se obtuvieron las siguientes lecturas, acorde a la proporción y concentración de gas, además se toman medidas acorde a la temperatura y humedad relativas del ambiente.

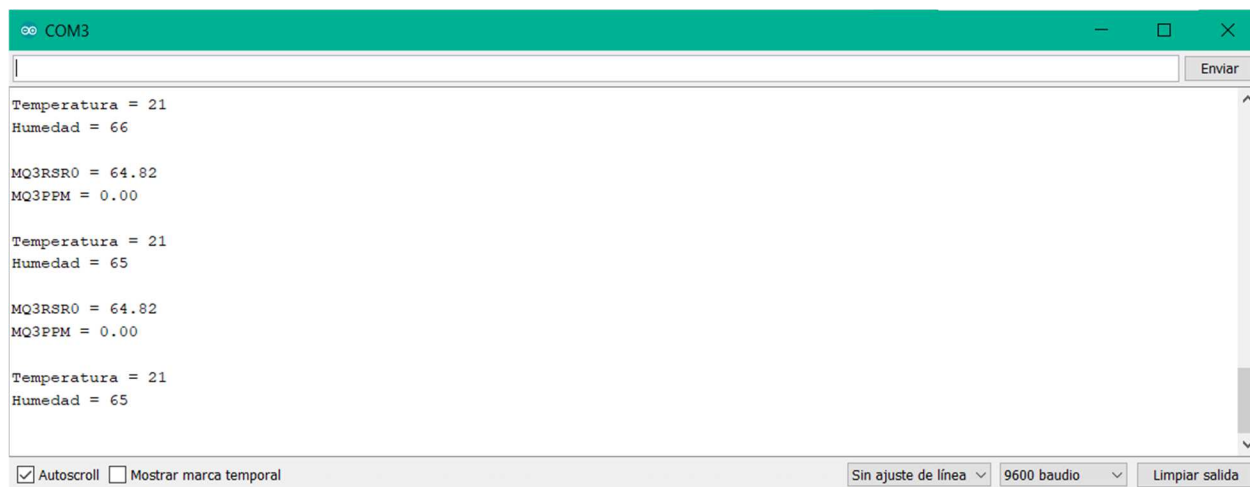


Figura 35. Respuesta del sensor MQ3 sin presencia de gas metano (CH₄) (Autoría propia, 2020).

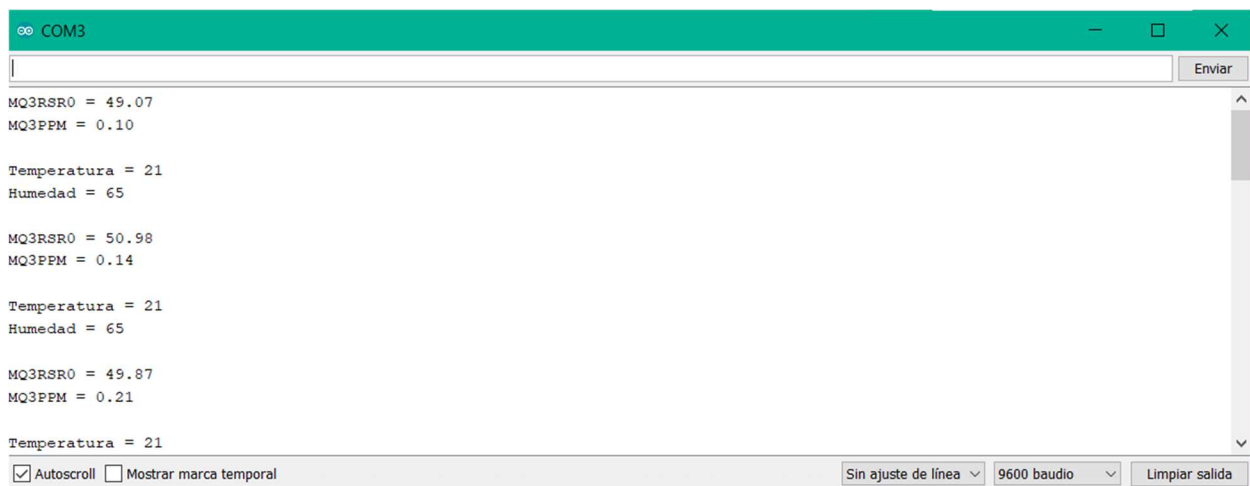


Figura 36. Respuesta del sensor MQ3 con presencia de gas metano (CH₄) (Autoría propia, 2020).

Para el sensor de gas MQ6

En primer lugar, se realizó pruebas del sensor sin la exposición de gas, y posteriormente se realizó pruebas con exposición de gas. Donde para este sensor se obtuvieron las siguientes lecturas, acorde a la proporción y concentración de gas, además se toman medidas acorde a la temperatura y humedad relativas del ambiente.

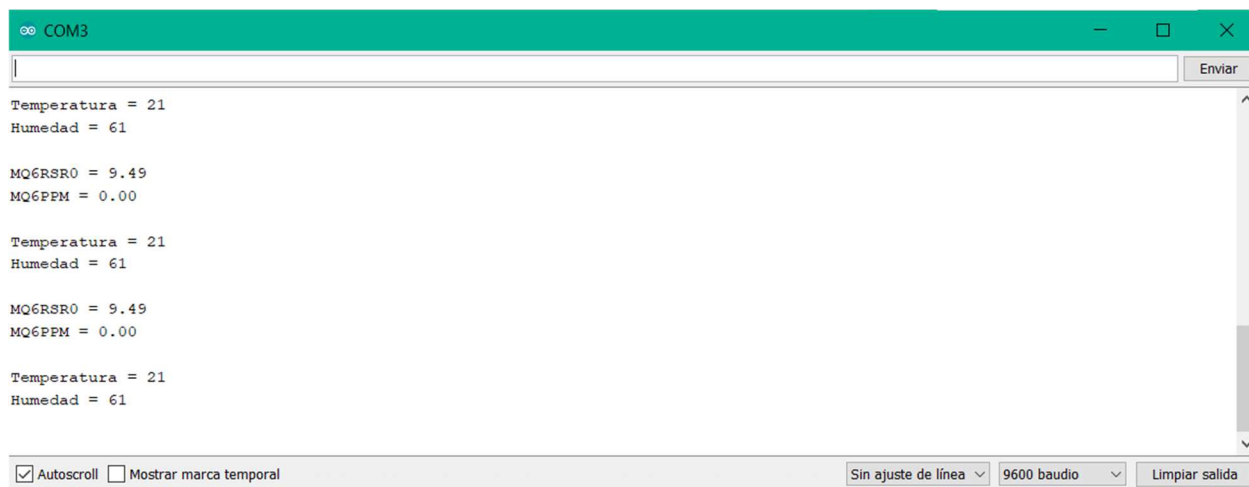


Figura 37. Respuesta del sensor MQ6 sin presencia de gas propano y butano (GLP) (Autoría propia, 2020).

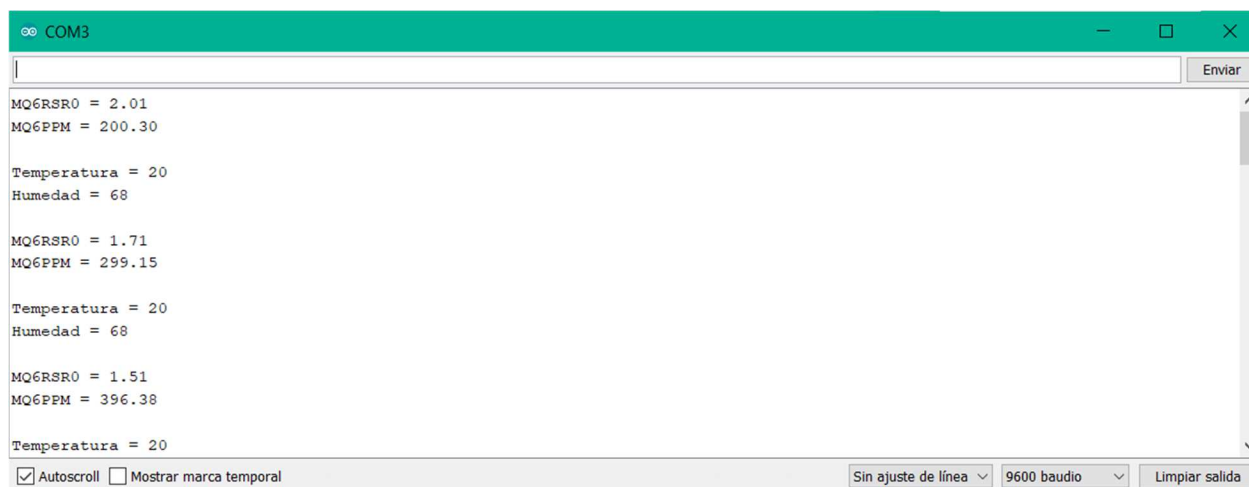


Figura 38. Respuesta del sensor MQ6 con presencia de gas propano y butano (GLP) (Autoría propia, 2020).

Para el sensor de temperatura y humedad DHT22

Para verificar el óptimo funcionamiento del sensor dht22, el cual se seleccionó para tomar medidas de temperatura y humedad, se realizaron pruebas para la generación de lecturas acorde a la temperatura y humedad relativas en el ambiente del área de trabajo, donde la lectura de la temperatura se genera en grados centígrados, debido a la escala que se toma o maneja en Colombia.

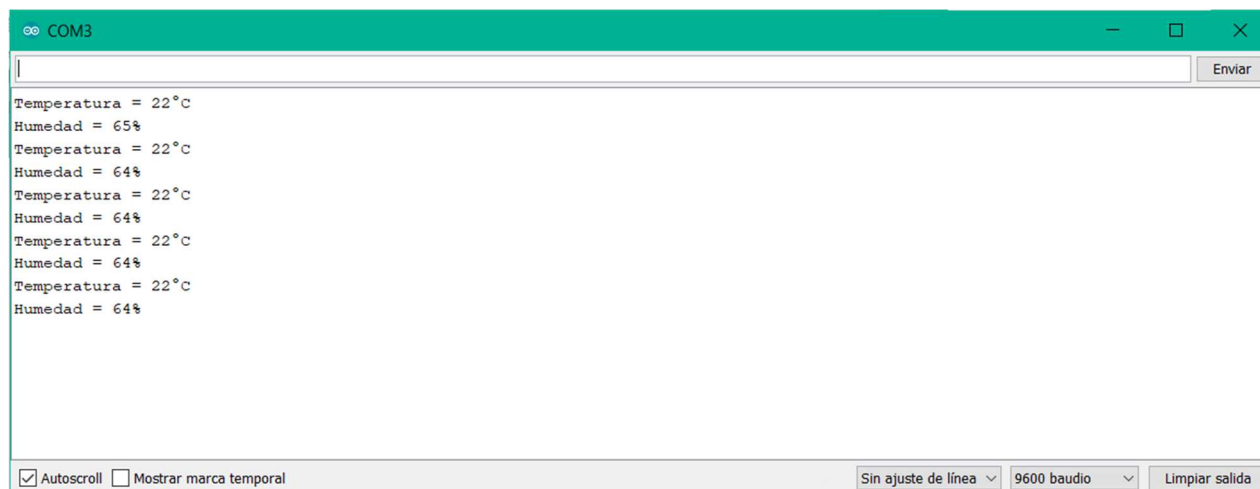


Figura 39. Respuesta del sensor dht22, para la temperatura y humedad (Autoría propia, 2020).

Finalizada las pruebas de funcionamiento para cada sensor de gas que conforma el arreglo de sensores de gas de la nariz electrónica, se infiere lo siguiente:

Para cada sensor y su configuración correspondiente, respondieron de manera efectiva ante la exposición de los diferentes gases a detectar, y de igual manera nos arrojaban lecturas acordes a la realidad, en cuanto a la proporción de gas y la concentración de gas presente en el aire.

También se evidencio la fuerte dependencia entre las variables de proporción de gas (RS/R0) y concentración (PPM). Donde se evidencia una correlación inversamente proporcional, puesto que, al reducir la variable proporción de gas, la concentración de este de aumenta.

De igual forma, se evidencio un cambio mínimo de las lecturas de temperatura y humedad en las pruebas realizadas entra cada transición de funcionamiento de los sensores. Sin embargo, estos cambios no entorpecieron el funcionamiento de los sensores de gas.

También cabe resaltar que la repuesta de los sensores de gas se generó a una distancia considerable de la fuente de gas, de modo que para la pruebas realizadas el arreglo de sensores se distancio de la fuente de generación de gas aproximadamente 45cm, donde los sensores lograban tomar las medidas a la distancia de 45cm presentadas en los apartados anteriores. Todo este procedimiento se realizó con todas la medidas de prevención para no generar ningún daño físico

tanto al lugar, como a las persona presentes en el lugar.

Adquisición y almacenamiento de datos.

Para esta parte del proyecto el arreglo de sensores ya fue calibrado y programado de forma que podamos obtener lecturas en cuanto a la proporción y concentración para la determinación de gas. Sin embargo, estas lecturas deben ser almacenadas de forma que se puedan analizar con más detalle, por lo cual se opta por la decisión de almacenar dichas lecturas en una base de datos, incluyendo las lecturas generadas por el sensor de temperatura y humedad, y en este caso se utiliza un sistema de gestión de bases de datos bajo la herramienta de MySQL. No obstante, el IDE de Arduino no posee una librería que nos permita realizar una conexión desde Arduino y MySQL de forma directa. Debido a esto, se opta por usar peticiones HTTP GET, lo que nos permite enviar todo tipo de peticiones HTTP a una URL específica y procesar la respuesta de servidor HTTP.

Lo cual nos indica que es necesario conectar el circuito de arreglo de sensores con una red ethernet mediante el modelo TCP/IP, y debido a esto es necesario incluir el módulo de ethernet mini (ENC28J60) al circuito como se ve en la figura 40, donde dicho modulo permite conectar cualquier microcontrolador como la tarjeta de Arduino a la red Ethernet y de esa forma poder enviar y recibir datos desde una red local.

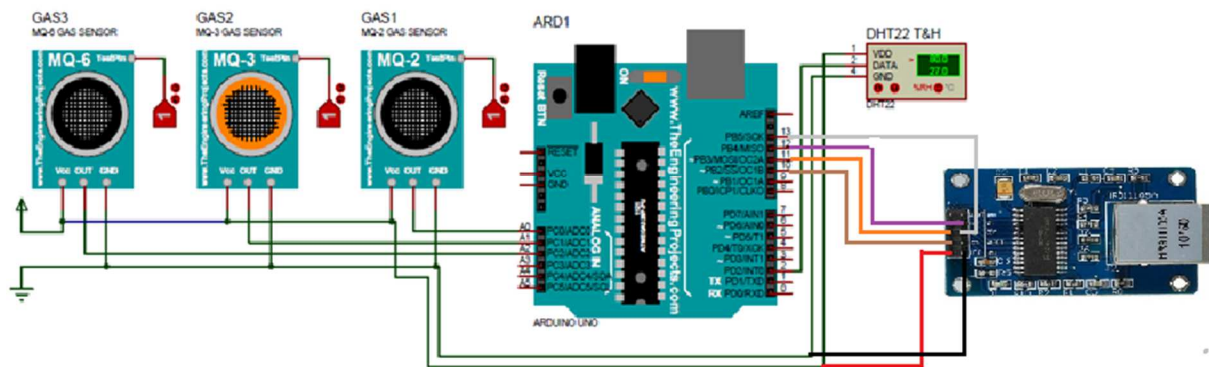


Figura 40. Bosquejo para la integración del módulo ethernet al circuito, arreglo de sensores (Autoría propia, 2020).




Figura 41. Implementación de integración del módulo ethernet al circuito, arreglo de sensores (Autoría propia, 2020).

Una vez realizada la conexión del módulo al circuito, se procede a realizar la conexión del módulo con el router domestico a través de un cable de red (Rj45). Y se introduce en el código de Arduino, la librería *Ethernet.h* la cual maneja la pila del protocolo TCP/IP, y la librería *SPI.h*, y se define un nuevo cliente con el comando: *EthernetClient cliente*. Por consiguiente, se asignan direcciones fijas tanto de IP, como puerta de red predeterminada y MAC. De esta forma se ve en la figura 42.

```
#include <Ethernet.h>
#include <SPI.h>
#include <DHT.h>
#include <DHT_U.h>

byte mac[] = {0xDE, 0xAD, 0xBE, 0xEF, 0xFF, 0xEE}; // Dirección MAC
byte ip[] = { 192,168,0,50 }; // Dirección IP del Arduino
byte server[] = { 192,168,0,1 }; // Dirección IP del servidor
EthernetClient cliente;//objeto del ethernet
```

Figura 42. Librerías y asignación de direcciones fijas (ethernet) (Autoría propia, 2020).

Posteriormente se realiza la verificación de conexión con el servidor, mediante las siguientes sentencias en el código.

```
// Proceso de envio de muestras al servidor
Serial.println("Envio de dato, conectando...");
if (cliente.connect(server, 80)>0) { // Conexion con el servidor(client.connect(server, 80)>0
  cliente.print("GET/ conexion_arduino.php?MQ2RSR0_php="); // Enviamos los datos por GET
  cliente.println(MQ2RSR0);
  cliente.print("MQ2PPM_php= ");
  cliente.println(MQ2PPM);
  cliente.print("MQ3RSR0_php= ");
  cliente.println(MQ3RSR0);
  cliente.print("MQ3PPM_php= ");
  cliente.println(MQ3PPM);
  cliente.print("MQ6RSR0_php= ");
  cliente.println(MQ6RSR0);
  cliente.print("MQ6PPM_php= ");
  cliente.println(MQ6PPM);
  cliente.print("Temperatura_php= ");
  cliente.println(Temperatura);
  cliente.print("Humedad_php= ");
  cliente.println(Humedad);
  cliente.println(" HTTP/1.1");
  cliente.println("User-Agent: Arduino 1.1");
  cliente.println();
}
else {
  Serial.println("Fallo en la conexion");
  Serial.println(" ");
}
cliente.stop();
cliente.flush();
```

Figura 43. Conexión cliente – servidor (Autoría propia, 2020).

En la figura 43, se define un bucle en donde si la tarjeta de Arduino se conecta con el servidor mediante el puerto 80, se envía al servidor una petición de tipo GET con las diferentes variables de lecturas que se quieren almacenar en la base de datos. Si por el contrario la conexión con el servidor, se indica que no se pudo establecer conexión con el servidor, y finalmente se cierra la conexión.

Este proceso de conectar la tarjeta de Arduino y una base de datos de MySQL se realizó bajo programación PHP donde básicamente es un lenguaje destinado a tratar datos con servidores y mostrarlos por pantalla principalmente, se crean 3 archivos PHP con el fin de poder leer las lecturas enviadas desde el arreglo de sensores y poder enviarlas a la base de datos.

El primer paso fue crear una base de datos la cual se llamó como: narizelect, y dentro de esta base crear una tabla llamada *datosredsensor* donde serán almacenados las correspondientes lecturas de los sensores, incluyendo una columna denominada *id* en la cual se registrará cada operación de movimiento ejecutada. En la figura 44, se observa la estructura que se definió para la

tabla donde serán almacenados los datos de los sensores.


#	Nombre	Tipo	Cotejamiento	Atributos	Nulo	Predeterminado	Comentarios	Extra
1	Id 	int(234)			No	Ninguna		AUTO_INCREMENT
2	MQ2RSR0	float			No	Ninguna		
3	MQ2PPM	float			No	Ninguna		
4	MQ3RSR0	float			No	Ninguna		
5	MQ3PPM	float			No	Ninguna		
6	MQ6RSR0	float			No	Ninguna		
7	MQ6PPM	float			No	Ninguna		
8	Temperatura	int(2)			No	Ninguna		
9	Humedad	int(2)			No	Ninguna		
10	Datetime	datetime			No	current_timestamp()		

Figura 44. Estructura para la tabla de base de datos (Autoría propia, 2020).

A continuación, se relacionan los archivos PHP para la gestión de conexión de datos con la tarjeta de Arduino y la base de datos de MySQL.

En la figura 45, se observa el código escrito en PHP donde se realiza una conexión privada con el fin de evitar conexiones de usuarios terceros a la base de datos y estos puedan manipular los datos almacenados.

```

<?php
class conexion
{
    private $servidor;
    private $usuario;
    private $contrasena;
    private $basedatos;
    public $conexion;

    public function __construct(){
        $this->servidor = "localhost";
        $this->usuario = "root";
        $this->contrasena = "pass";
        $this->basedatos = "narizelect";
    }

    function conectar(){
        $this->conexion = new PDO("mysql:host=$this->servidor;dbname=$this->basedatos","$this->usuario","$this->contrasena");
    }

    function cerrar(){
        $this->conexion->close();
    }
}
?>

```

Figura 45. Conexión privada PHP (Autoría propia, 2020).

En la figura 46, se observa el código escrito en PHP, para la introducción de las lecturas de los sensores en una tabla de la base de datos, la tabla se denomina “datosredsensor”.

```

<?php
class Herramienta{
    private $conexion;

    function __construct(){
        require_once("conexion_privada.php");
        $this->conexion = new conexion();
        $this->conexion->conectar();
    }

    public function ingresar_datos($MQ2RSR0_php, $MQ2PPM_php, $MQ3RSR0_php, $MQ3PPM_php, $MQ6RSR0_php, $MQ6PPM_php, $Temperatura_php, $Humedad_php){
        $sql = " insert into datosredsensor values (null, ?, ?, ?, ?, ?, ?, ?, ? now()) ";
        $stmt = $this->conexion->conexion->prepare($sql);

        $stmt->bindValue(1, $MQ2RSR0_php);
        $stmt->bindValue(2, $MQ2PPM_php);
        $stmt->bindValue(3, $MQ3RSR0_php);
        $stmt->bindValue(4, $MQ3PPM_php);
        $stmt->bindValue(5, $MQ6RSR0_php);
        $stmt->bindValue(6, $MQ6PPM_php);
        $stmt->bindValue(7, $Temperatura_php);
        $stmt->bindValue(8, $Humedad_php);

        if($stmt->execute()){
            echo "Ingreso Exitoso";
        }else{
            echo "no se pudo registrar datos";
        }
    }
}
?>

```

Figura 46. Conexión con la base de datos e introducción de lecturas a la tabla (Autoría propia, 2020).

En la figura 47, se observa el código escrito PHP, para conexión intermediaria entre la tarjeta de Arduino y la base de datos: narizelect.

```

<?php
require_once("herramienta_introducir_datos.php");

$herramienta = new Herramienta();
/*if($GET["MQ2RSR0"] == null or $GET["MQ2PPM"] == null or $GET["MQ3RSR0"] == null or $GET["MQ3PPM"]
== null or $GET["Temperatura"] == null or $GET["Humedad"] == null){
echo "No se pudo obtener valores desde arduino";exit;
}else{*/
$ingresar_dato = $herramienta->ingresar_datos($GET["MQ2RSR0_php"],$GET["MQ2PPM_php"],$GET["MQ3RSR0_php"],$GET["MQ3PPM_php"],$GET["MQ6RSR0_php"],$GET["
MQ6PPM_php"],$GET["Temperatura_php"],$GET["Humedad_php"]);
//
?>

```

Figura 47. Conexión Arduino y base de datos (Autoría propia, 2020).

Y finalizando en la figura 48, se observa los datos de las lecturas que generan los sensores que se almacenaron de manera automática, y de forma correcta en la base de datos, en la tabla datosredsensor.

Id	MQ2RSR0	MQ2PPM	MQ3RSR0	MQ3PPM	MQ6RSR0	MQ6PPM	Temperatura	Humedad	Datetime
1	9.84	0	64.33	0	9.91	0	21	57	2020-10-28 14:53:39
2	9.86	0	66.34	0	9.91	0	21	57	2020-10-28 15:01:28
3	9.86	0	66.37	0	9.91	0	21	57	2020-10-28 15:01:28
4	9.84	0	66.33	0	9.93	0	21	58	2020-10-28 15:04:17
5	9.87	0	66.36	0	9.92	0	21	57	2020-10-28 15:04:17
6	9.8	0	66.32	0	9.94	0	21	57	2020-10-28 15:05:35
7	9.86	0	66.35	0	9.91	0	21	57	2020-10-28 15:05:35
8	5.24	202.65	49.09	0.1	2.01	200.3	21	58	2020-10-28 15:11:00
9	4.96	248.72	50.99	0.13	1.51	396.39	21	57	2020-10-28 15:11:00
10	4.66	298.85	50.99	0.13	1.71	299.15	21	58	2020-10-28 15:13:18
11	9.86	0	66.36	0	9.92	0	21	57	2020-10-28 15:13:18

Figura 48. Almacenamiento de lecturas en la tabla (Autoría propia, 2020).

Diseño y entrenamiento de una red neuronal artificial.

Arquitectura de la red neuronal artificial. En este apartado del proyecto se procede a realizar el diseño de una red neuronal para la predicción y clasificación de los distintos gases derivados del gas natural presentes el aire ambiente residencial. A partir de esta información se realizó un análisis respecto al diseño a realizar, y conforme a las necesidades de este proyecto se cuestionó una serie de parámetros que conforman una red neuronal artificial como lo es el número de entradas a la red, el número de capas ocultas, el número de neuronas de las capas ocultas y de salida y la función de activación a emplear.




Figura 49. Arquitectura de la red neuronal artificial (Autoría propia, 2020).

De esta manera se generó el modelo de una red neuronal artificial de tipo Perceptrón multicapa (MLP), con conexión hacia adelante como se muestra en la figura 49, para este tipo de modelo de red neuronal le permite aprender tanto modelos no lineales como lineales. Este modelo de red lo

conforma una capa de entrada, con dos neuronas para la entrada de datos a la red, una capa oculta conformada con una cantidad de neuronas n , y una capa de salida con una sola neurona para la salida de la red, en la cual define los valores de salida definidos.

Dataset. A continuación, se realiza la construcción del conjunto de datos (dataset), para el entrenamiento de la red neuronal artificial. El dataset se construyó a partir de las lecturas que se registraron y se almacenaron en la base de datos narizelect, en función de las respectivas lecturas que se generaron del arreglo de sensores en cuanto a la proporción de gas y la concentración de gas de los respectivos gases detectados.

El dataset se construyó de la siguiente manera, dos variables de entrada a la red neuronal, en este caso la proporción y concentración de gas (RS/R0 y PPM) y una variable de salida denominada Gas para la predicción y clasificación de cada gas.

Donde la variable Gas se denominó de la siguiente manera:

Para el valor de “0”, como CO, determinación de gas monóxido de carbono.

Para el valor de “1”, como GLP, determinación de gas butano y propano.

Para el valor de “2”, como CH₄, determinación de gas metano.

Ejemplo de cómo quedo el set de datos:

RS/R0	PPM	GAS
5.24	202.65	0
4.96	248.72	0
4.66	298.85	0
4.3	399.23	0
4.04	500.48	0
2.01	200.3	1
1.51	396.39	1
1.71	299.15	1
1.34	503.53	1
1.23	600.37	1
49.09	0.1	2
50.99	0.13	2
49.87	0.2	2
48.77	0.3	2
47.66	0.4	2

Figura 50. Ejemplo dataset (Autoría propia, 2020).

Entrenamiento de la red neuronal artificial. Una vez establecidos los parámetros de arquitectura de la red neuronal para la predicción y clasificación de los derivados del gas natural, gases como el metano, propano, butano y monóxido de carbono. Se procede a realizar la implementación y entrenamiento de la red neuronal. El entrenamiento de una red neuronal es fundamental para que esta pueda ser utilizada, este entrenamiento consiste en ajustar constantemente los pesos sinápticos asociados a cada neurona de la capa de entrada y las capas ocultas, hasta que la respuesta de la capa de salida sea lo más parecida a los datos de salida deseados que se definieron con anterioridad.

Bajo este principio, para la implementación y entrenamiento de la red neuronal se opta por usar el software Orange debido a sus ventajas de implementación. Orange al ser un software totalmente gratuito que está basado en programación visual, lo cual permite a los usuarios que no poseen grandes conocimientos de programación, realizar numerosas técnicas de Machine Learning y análisis predictivo. Orange permite crear flujos de trabajos, mediante la vinculación de widgets predefinidos por el usuario.

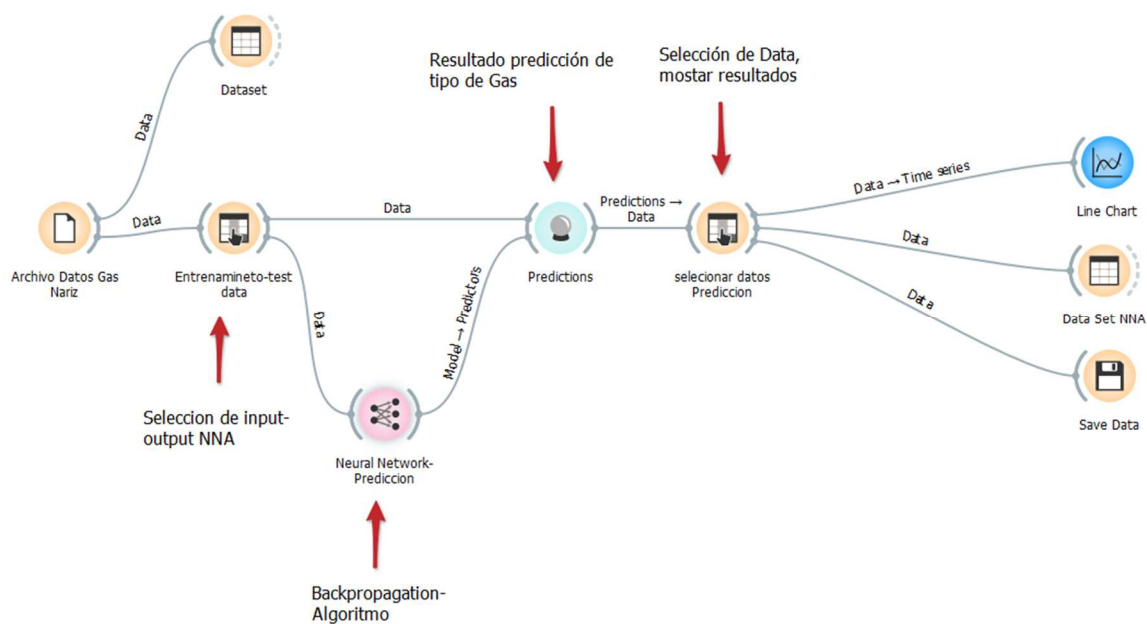


Figura 51. Diagrama diseño de red neuronal artificial para la predicción y clasificación (Autoría propia, 2020).

En la figura 51, se observa el flujo de trabajo para el diseño y estructura que se definió para el

modelo red neuronal artificial, realizada bajo el software Orange. Este flujo de trabajo consta de 9 widgets de trabajo, los cuales incluyen un widget para introducción del dataset, uno con el algoritmo de entrenamiento de la red neuronal, uno para realizar la predicción y otros para representar gráficamente mediante estadísticas los resultados obtenidos del modelo de predicción y clasificación de la red neuronal.

Primero se situó un widget para insertar el dataset y otro para visualizar dicho dataset.

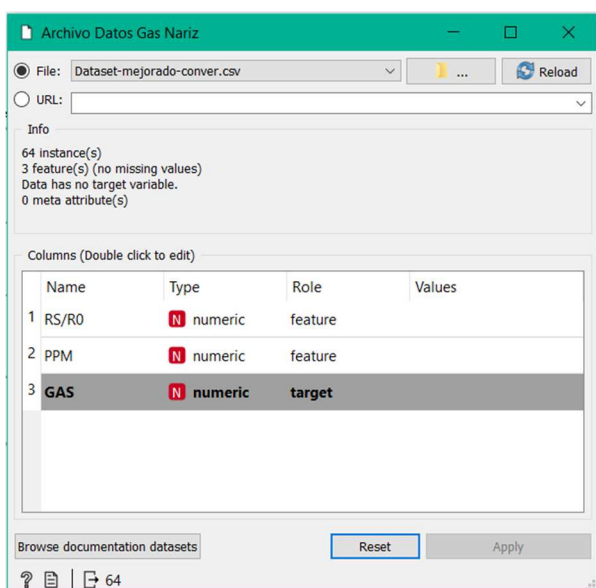


Figura 52. Widget para insertar el dataset (Autoría propia, 2020).

	GAS	RS/R0	PPM
1	0	5.24	202.65
2	0	4.96	248.72
3	0	4.66	298.85
4	0	4.30	399.23
5	0	4.04	500.48
6	0	3.80	601.37
7	0	3.62	697.52
8	0	3.45	803.36
9	0	3.32	893.14
10	0	3.24	1007.09
11	0	3.05	1103.94
12	0	3.02	1218.68
13	0	2.58	2012.25
14	0	2.75	1506.31
15	0	2.22	3009.73
16	0	2.04	3642.08
17	0	1.99	3992.34
18	0	1.83	4969.57
19	0	1.70	6056.32
20	0	1.62	6975.23

Figura 53. Widget para visualizar el dataset (Autoría propia, 2020).

El dataset para el entrenamiento de una red neuronal es fundamental, ya que en el dataset se recopila todos los datos que se pretenden presentar a la red neuronal conocidos como ejemplos de entrenamiento, en este caso para la RNA para la predicción y clasificación de gas natural en ambientes residenciales se le presentan datos de entradas correspondientes a la proporción y concentración de gas, dichos datos definidos como variables de tipo numérico, para el caso de variables de entrada como RS/R0 y PPM, y una variable de tipo numérico para los datos de salida deseada, en este caso los datos de salida se definieron con tres valores 0, 1 y 2. Donde estos datos se establecieron para identificar el tipo de gas presente en el aire conforme a los datos de entrada, de esta forma se puede observar en la imagen 50 y 53.

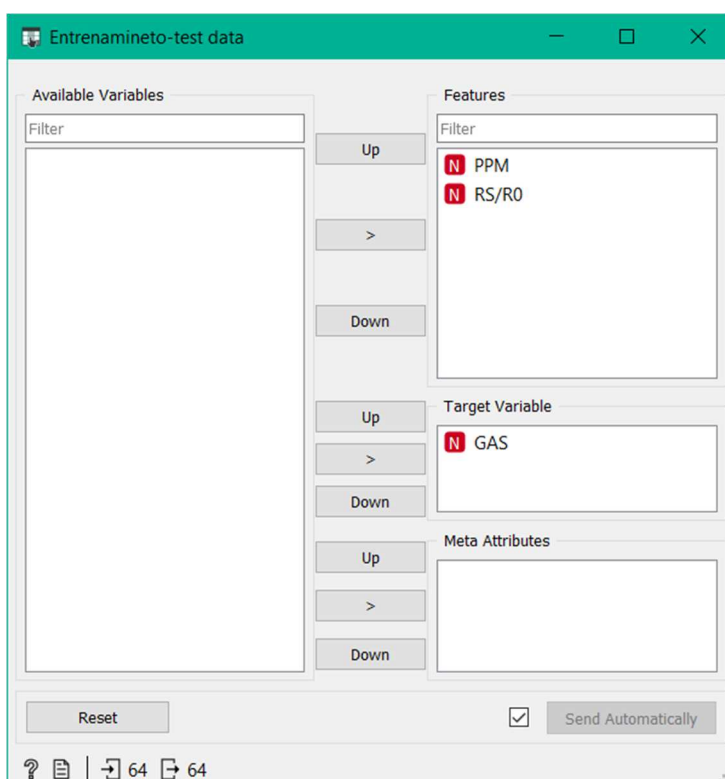


Figura 54. Asignación de entradas y valores (Autoría propia, 2020).

Generado el dataset, se procede a vincular un widget de input y output al widget del dataset. Este widget nos permite seleccionar las variables de entrada y salida que tendrá la RNA. Estableciendo como entradas a la RNA, las variables RS/R0 y PPM, y de esa manera se establece la variable Gas como variable de salida de la RNA. Como se presenta en la figura 54.

Posteriormente se vincula al flujo de trabajo el widget de algoritmo para el entrenamiento de la RNA.

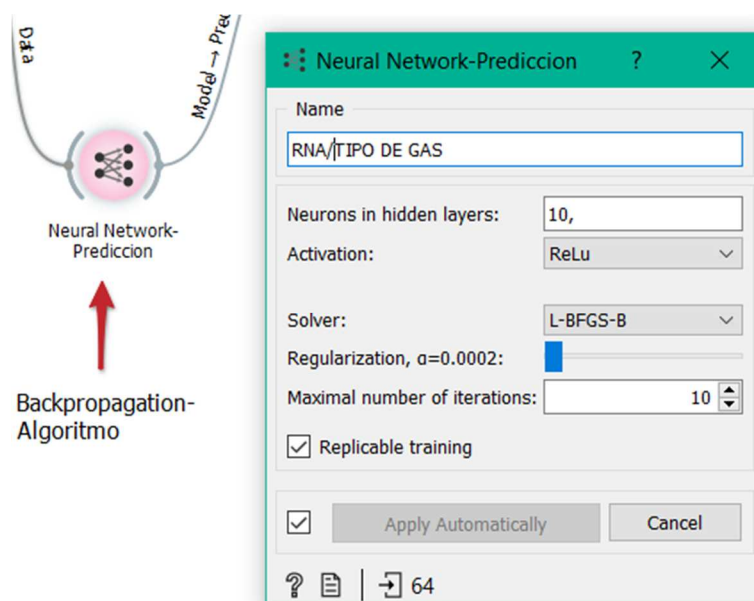


Figura 55. Algoritmo de entrenamiento de la RNA (Autoría propia, 2020).

En este widget es preciso establecer los diferentes parámetros con los que se entrenara la RNA, como se muestra en la figura 55. En consecuencia, los parámetros que se deben definir son los siguientes:

- Se debe asignar nombre a la RNA.
- Se debe definir el número de neuronas que tendrá la o las capas ocultas que conforman la RNA.
- Se debe definir la función de activación de las neuronas de la RNA.
- Se debe definir el método de optimización de los pesos que tendrá la RNA.
- Se debe definir el número de iteraciones para el entrenamiento de la RNA.

Conforme a esta información y a las necesidades de este proyecto se establecieron los siguientes parámetros para el entrenamiento de la RNA.

- **Nombre de la RNA:** El nombre de la red neuronal artificial se definió como tipo de gas, ya que la finalidad de esta esta red es poder predecir y clasificar el tipo de gas presente en el entorno residencial.
- **Numero de neuronas ocultas:** En el entrenamiento de una RNA no es posible predeterminedar el número de capas ocultas y el número de neuronas que tendrá cada capa oculta, a diferencia de la capa de entrada y capa de salida que si es posible definir el número

de neuronas que cada una tendrá desde el inicio de diseño. A medida que se entrena la red y esta evoluciona, se van definiendo a prueba y error el número de neuronas que tendrá cada capa oculta. De esta forma se establece un número de neuronas aleatorio, en este caso 10 neuronas y a partir de este se va modificando posteriormente este valor.

- **Función de activación:** Se definió para cada neurona de la capas ocultas, la función de unidad lineal rectificada (ReLU). Debido a que esta función presentó mejor rendimiento para la predicción y clasificación, frente a otras funciones de activación con las que se realizaron pruebas, pero no mostraron una mejor predicción.
- **Método de optimización de pesos sinápticos:** Se aplicó el método L-BFGS-B (Limited-memory Broyden–Fletcher–Goldfarb–Shanno) es un optimizador en la familia de métodos cuasi-Newton, el cual es uno de los mejores, ya que presenta una convergencia rápida para la predicción.
- **Número de iteraciones:** De igual manera que el número de neuronas en las capas ocultas no es posible determinar en cuántas iteraciones la red neuronal será capaz de aprender los datos de entrenamiento, y de igual forma este valor de iteraciones se modifica a medida que evoluciona la red, a prueba y error, y por consiguiente se selecciona un valor aleatorio de 10 iteraciones inicialmente.
- **Tipo de entrenamiento:** Se emplea un entrenamiento de propagación de errores hacia atrás (Backpropagation), se conoce como un entrenamiento supervisado que es empleado en redes multicapa, donde a partir de un error generado en la red se ajusta el valor de los pesos sinápticos en función de minimizar lo más posible dicho error generado.
- **Métrica MSE:** Se utiliza principalmente para evaluar la tasa de error de predicción y el rendimiento del modelo de red durante el entrenamiento, donde MSE (Error Cuadrático Medio) representa la diferencia entre los valores originales y predichos extraídos al cuadrado de la diferencia promedio sobre el conjunto de datos.

De manera rápida se resume el comportamiento que tendrá esta RNA para la predicción y clasificación de distintos gases que componen al gas natural. A la RNA se le presentan los datos de entrada y los datos deseados para la salida, estos datos se propagan hacia adelante estimulando cada neurona, pasando por todas la capas ocultas y de salida, los valores para los pesos sinápticos asociados a cada neurona en las primeras iteraciones el software Orange los establece de manera aleatoria, el resultado que proporciona cada neurona se somete a una función de activación que determina si la neurona se activa o no y envía los datos a la siguiente neurona conectada. Finalmente, la red neuronal compara los resultados que tuvo la red neuronal en cada iteración con los resultados esperados, de manera que, si se generan errores, por el algoritmo de Backpropagation, se retroalimenta ese error desde la última capa hasta la capa de entrada, encontrando el error cuadrático medio que genero cada neurona y modificando los valores de los pesos sinápticos hasta el punto de minimizar el valor del error lo mayor posiblemente. Hasta que la red neuronal encuentre los valores ideales de los pesos para cada neurona, y a la respuesta de la RNA sea lo más parecida a los datos de salida esperados. El comportamiento que tuvo esta RNA durante el entrenamiento se demuestra en las siguientes figuras. Donde se evidencia que, para obtener los resultados esperados, durante el entrenamiento se modificaron los valores para el numero de neuronas en la capa oculta y el número de iteraciones.




Figura 56. Representación gráfica, entrenamiento de la RNA (10/10) (Autoría propia, 2020).




Figura 57. Representación gráfica, entrenamiento de la RNA (50/10) (Autoría propia, 2020).




Figura 58. Representación gráfica, entrenamiento de la RNA (50/20) (Autoría propia, 2020).




Figura 59. Representación gráfica, entrenamiento de la RNA (50/50) (Autoría propia, 2020).




Figura 60. Representación gráfica, entrenamiento de la RNA (50/100) (Autoría propia, 2020).




Figura 61. Representación gráfica, entrenamiento de la RNA (100/100) (Autoría propia, 2020).

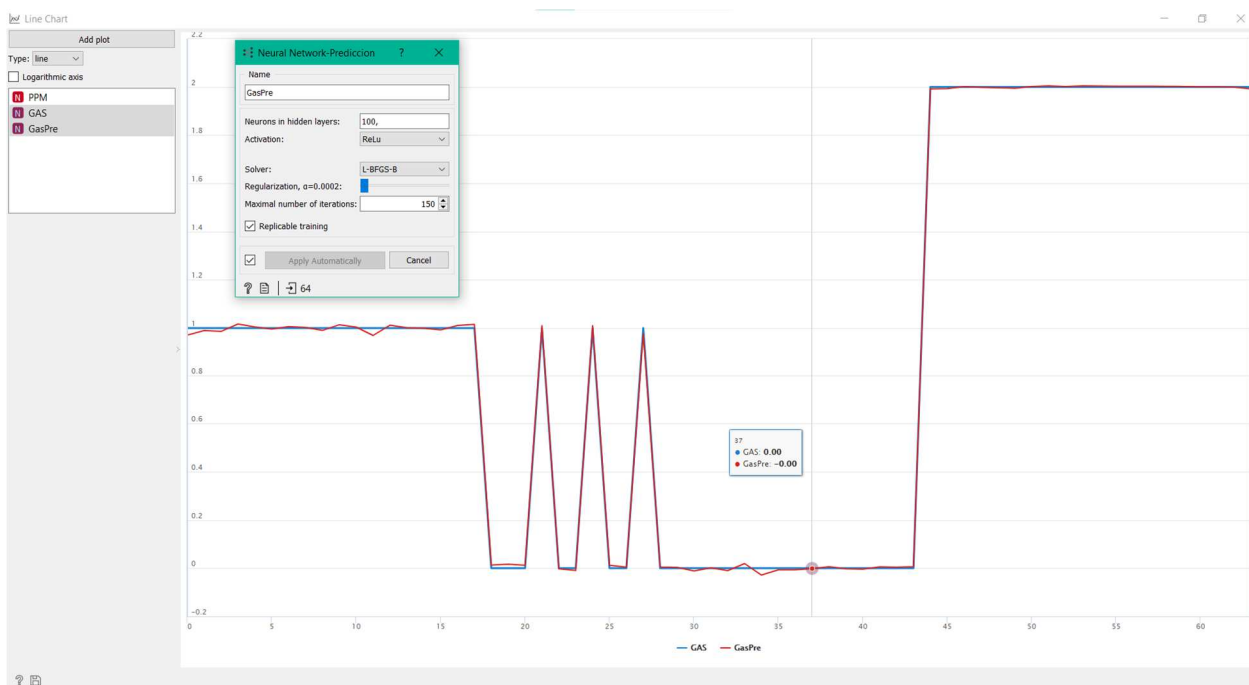


Figura 62. Representación gráfica, entrenamiento de la RNA (100/150) (Autoría propia, 2020).




Figura 63. Representación gráfica, entrenamiento de la RNA (100/200) (Autoría propia, 2020).

De acuerdo con la información que registra en la figuras presentadas anteriormente, el entrenamiento de la red neuronal artificial para la predicción y clasificación del tipo de gas evidencia que alcanzadas las 200 iteraciones y un número de 100 neuronas en la capa oculta la red neuronal es capaz de realizar la predicción correcta del tipo de gas, de acuerdo que los valores de salida de la red se asemejan casi un 90% de los valores reales deseados. De manera que el error cuadrático medio para este punto se encuentra cercano o igual al valor de 0.

En la tabla 8, se relaciona los parámetros de entrenamiento, y el error generado por cada uno de ellos.

Tabla 8.

Parámetros de entrenamiento

Numero de iteraciones	Numero de neuronas ocultas	MSE
10	10	0.168
10	50	0.179
20	50	0.121
50	50	0.002
100	50	0.001
200	100	0.000

Nota. Autoría de Adriana Morales.

Los parámetros presentados en la tabla, los conforman el número de iteraciones que tuvo la red, el número de neuronas en la capa oculta, y el valor del error cuadrático medio. Donde estos valores se modificaron de acuerdo con el error cuadrático medio generado para cada fase del entrenamiento, evidenciando de esa forma que a medida que se aumentaba el número de iteraciones y el número de neuronas, el valor del error cuadrático medio a la salida de la red neuronal disminuía, y a medida que esto sucedía los datos de salida era cada vez más semejantes a los valores reales de salida esperados.

RNA/TIPO DE GAS	GAS	PPM	RS/RO
1	0	202.65	5.24
2	-0	248.72	4.96
3	0	298.85	4.66
4	-0	399.23	4.30
5	0	500.48	4.04
6	0	601.37	3.80
7	0	697.52	3.62
8	-0	803.36	3.45
9	-0	893.14	3.32
10	-0	1007.09	3.24
11	0	1103.94	3.05
12	-0	1218.68	3.02
13	-0	2012.25	2.58
14	0	1506.31	2.75
15	0	3009.73	2.22
16	-0	3642.08	2.04
17	-0	3992.34	1.99
18	0	4969.57	1.83
19	0	6056.32	1.70
20	-0	6975.23	1.62
21	0	7977.02	1.51
22	0	8931.41	1.48
23	0	10070.88	1.43
24	1	200.30	2.01
25	1	396.39	1.51
26	1	299.15	1.71

Model	MSE	RMSE	MAE	R2
RNA/TIPO DE GAS	0.000	0.008	0.005	1.000

Figura 64. Resultados de predicción para el tipo de gas - 0 (Autoría propia, 2020).

Predictions

Show probabilities for

	RNA/TIPO DE GAS	GAS	PPM	RS/R0
27	1	1	503.53	1.34
28	1	1	600.37	1.23
29	1	1	700.90	1.15
30	1	1	789.96	1.09
31	1	1	896.65	1.04
32	1	1	989.46	0.98
33	1	1	1329.77	0.90
34	1	1	1737.43	0.80
35	1	1	1985.90	0.74
36	1	1	2367.92	0.69
37	1	1	2986.92	0.63
38	1	1	3985.88	0.56
39	1	1	4957.59	0.51
40	1	1	5911.18	0.48
41	1	1	6901.04	0.45
42	1	1	8000.22	0.43
43	1	1	9016.78	0.40
44	1	1	9950.33	0.39
45	2	2	0.10	49.09
46	2	2	0.13	50.99
47	2	2	0.20	49.87
48	2	2	0.30	48.77
49	2	2	0.40	47.66
50	2	2	0.50	47.13
51	2	2	0.60	46.61
52	2	2	0.69	46.64

Model	MSE	RMSE	MAE	R2
RNA/TIPO DE GAS	0.000	0.008	0.005	1.000

Restore Original Order

64

Figura 65. Resultados de predicción para el tipo de gas - 1 (Autoría propia, 2020).