

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE AGRONOMÍA



**DESARROLLO DE UN SOFT SENSOR PARA LA PREDICCIÓN DE pH EN LA
DIGESTIÓN ANAEROBIA**

TESIS

**QUE PARA OBTENER EL GRADO DE
MAESTRO EN CIENCIAS CON ORIENTACIÓN EN
INGENIERIA EN BIOSISTEMAS**

**PRESENTA
PEDRO JESÚS CAMARENA MARTÍNEZ**

GENERAL ESCOBEDO, NUEVO LEÓN

JUNIO 2024

UNIVERSIDAD AUTÓNOMA DE NUEVO LEÓN

FACULTAD DE AGRONOMÍA



**DESARROLLO DE UN SOFT SENSOR PARA LA PREDICCIÓN DE pH EN LA
DIGESTIÓN ANAEROBIA**

TESIS

**QUE PARA OBTENER EL GRADO DE
MAESTRO EN CIENCIAS CON ORIENTACIÓN EN
INGENIERÍA EN BIOSISTEMAS**

PRESENTA:

PEDRO JESÚS CAMARENA MARTÍNEZ

GENERAL ESCOBEDO, NUEVO LEÓN

JUNIO 2024

ESTA TESIS FUE REVISADA Y APROBADA POR EL COMITÉ PARTICULAR COMO
REQUISITO PARCIAL PARA OBTENER EL GRADO DE

MAESTRO EN CIENCIAS CON ORIENTACIÓN EN
INGENIERÍA EN BIOSISTEMAS

COMITÉ PARTICULAR

Dra. Nancy del Pilar Medina Herrera
Directora de Tesis

Dr. Salvador Tututi Ávila
Co-Director de Tesis

Dra. Julia Mariana Márquez Reyes
Asesora

Dr. Guillermo Cristian Guadalupe Martínez Ávila
Asesor

Santiago Rodríguez V.

Dr. Santiago Rodríguez Valderrama
Asesor

Dra. Juanita Guadalupe Gutiérrez Soto
Subdirectora de Posgrado e
Investigación

ESTA TESIS FUE APROBADA EN FORMATO, POR EL COMITÉ DE POSGRADO,
ATENDIENDO A EL ARTÍCULO 123, DEL REGLAMENTO GENERAL DEL
SISTEMA DE POSGRADO DE LA UANL.

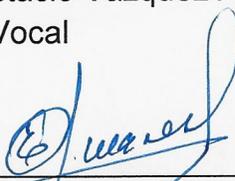
COMITÉ DE POSGRADO


Dra. Juanita Guadalupe Gutiérrez Soto
Presidenta


Dr. Celestino García Gómez
Secretario


Dra. Lidia Rosaura Salas Cruz
Vocal


Ph.D. Rigoberto Eustacio Vázquez Alvarado
Vocal


Ph.D. Emilio Olivares Sáenz
Vocal


Dra. Sughey Ramona Sinagawa García
Vocal


Dr. Guillermo Niño Medina
Vocal

ABREVIATURAS

AGV	Ácidos grasos volátiles
AI	Inteligencia artificial
ANN	Redes neuronales artificiales
CNN	Redes neuronales de convoluciones
DA	Digestión anaerobia
DL	Aprendizaje profundo
EROI	Retorno de energía sobre la inversión
EV	Estiércol de vaca
KNN	Vecinos cercanos
LSTM	Memoria larga a corto plazo
MAPE	Error porcentual absoluto medio
ML	Aprendizaje automático
MSE	Error cuadrático medio
PCB	Placa de circuito impresa
pH_RFV	pH de los residuos de frutas y verduras
RF	Bosques aleatorios
RFV	Residuos de frutas y verduras
RNN	Redes neuronales recurrentes
SHAP	Explicaciones aditivas de Shapley
SV	Sólidos volátiles
SVM	Máquinas de soporte vectorial
TRH	Tiempo de retención hidráulico

NOMENCLATURA

b_f, b_i, b_c, b_o	Sesgos
CH ₄	Metano
CO ₂	Dióxido de carbono
C_t	Estado de la célula
C_{t-1}	Estado previo de la célula
\tilde{C}_t	Compuerta de actualización
f_t	Compuerta de olvido
h_t	Estado oculto
h_{t-1}	Estado oculto previo
i_t	Compuerta de entrada
o_t	Compuerta de salida
$\tanh(\cdot)$	Función tangente hiperbólica
W_f, W_i, W_c, W_o	Pesos
x_t	Datos de entrada
X	Valor
$X_{escalado}$	Valor escalado
X_{max}	Valor máximo
X_{min}	Valor mínimo
y_i	Valor real
\hat{y}_i	Valor predicho
$\sigma(\cdot)$	Función sigmoide

ÍNDICE

ABREVIATURAS	v
NOMENCLATURA	vi
ÍNDICE	vii
ÍNDICE DE CUADROS	ix
ÍNDICE DE FIGURAS	x
RESUMEN	xi
ABSTRACT	xii
INTRODUCCIÓN	1
HIPÓTESIS	4
OBJETIVO GENERAL	5
1.1 Objetivo General	5
1.1.1 Objetivos específicos	5
REVISIÓN DE LITERATURA	6
2.1 Digestión Anaerobia	6
2.1.1 Biorreactores	8
2.1.2 Condiciones de Operación de la Digestión Anaerobia	10
2.1.3 Biogás	14
2.2 Sistemas de Instrumentación	15
2.2.1 Sistemas de Monitoreo en la Digestión Anaerobia	15
2.3 Inteligencia Artificial	16
2.3.1 Aprendizaje Profundo	16
2.3.2 Inteligencia Artificial en la Digestión Anaerobia	19
2.4 <i>Soft Sensors</i>	20
MATERIALES Y MÉTODOS	21
3.1 Plan de Trabajo	21
3.2 Biodigestor	22
3.3 Inóculo	23

3.4	Sustrato	24
3.5	Instrumentación y Monitoreo.....	25
3.6	Protocolo de Operación	27
3.7	Procesamiento y Análisis de Datos de la Digestión Anaerobia	28
3.8	Análisis de Relevancia de las Variables.....	28
3.9	<i>Soft Sensor – Long Short-Term Memory</i> –.....	29
RESULTADOS Y DISCUSIÓN		31
4.1	Desempeño y Análisis de la Digestión Anaerobia	31
4.2	Ajuste y Rendimiento del <i>Soft Sensor</i>	36
4.2.1	Selección de las Variables de Entrada.....	36
4.2.2	Optimización del <i>Soft Sensor</i>	39
4.2.3	Evaluación del <i>Soft Sensor</i>	40
4.3	Limitaciones Relacionadas con los Sensores	42
CONCLUSIONES.....		43
RECOMENDACIONES		44
REFERENCIAS BIBLIOGRÁFICAS		45
ANEXOS		61

ÍNDICE DE CUADROS

Cuadro	Página
Cuadro 1. Rol de comunidades microbianas en las etapas de la digestión anaerobia (adaptado de Paritosh <i>et al.</i> , 2017).	7
Cuadro 2. Configuraciones de sistemas de co-digestión.....	12
Cuadro 3. Rangos de pH de acuerdo con la etapa de la digestión anaerobia.....	13
Cuadro 4. Proporciones másicas del sustrato	24
Cuadro 5. Caracterización del estiércol y frutas y verduras.....	25
Cuadro 6. Sensores y sus variables de medición	25
Cuadro 7. Hiperparámetros utilizados en la búsqueda por cuadrícula.	29
Cuadro 8. Hiperparámetros seleccionados por la búsqueda en cuadrícula.	39

ÍNDICE DE FIGURAS

Figura	Página
Figura 1. Etapas de la digestión anaerobia.	6
Figura 2. Pretratamientos utilizados en la digestión anaerobia.	11
Figura 3. Diagrama del funcionamiento de un modelo <i>Long Short-Term Memory</i>	17
Figura 4. Etapas del plan de trabajo.....	21
Figura 5. Diagrama de conexiones y tuberías.	23
Figura 6. PCB para el monitoreo del biodigestor.	26
Figura 7. Diagrama de flujo del código del Esp32.	27
Figura 8. Distribución de datos de entrenamiento, validación y prueba	29
Figura 9. Concentración de metano.	32
Figura 10. Concentración de dióxido de carbono.	32
Figura 11. Producción de biogás acumulado.....	33
Figura 12. Comportamiento de pH.	33
Figura 13. Temperatura del biorreactor.....	34
Figura 14. Diagrama de caja de las variables monitoreadas.	35
Figura 15. Alimentación con estiércol (a), alimentación con RFV (b), pH de los RFV (c), extracción de gas (d) y agitación (e).	36
Figura 16. Correlación de Pearson.....	37
Figura 17. Correlación de Spearman.....	38
Figura 18. MSE en los datos de entrenamiento y validación.....	40
Figura 19. Resultado de las predicciones del soft sensor.....	41

RESUMEN

La digestión anaerobia (DA) emerge como una estrategia de gestión para los desechos orgánicos generados en entornos industriales, urbanos y rurales. La DA se destaca como una tecnología eficiente para convertir desechos orgánicos en bioenergía, especialmente aquellos con alto contenido de humedad como los residuos de frutas y verduras (RFV). No obstante, la fácil acidificación durante la hidrólisis de los RFV presenta desafíos, por lo que es necesario la aplicación de estrategias de control eficientes. Los modelos de aprendizaje automático se consideran una herramienta clave en la optimización y control de la DA.

Se instaló un biodigestor semi-continuo con un volumen operativo de 11.5 L, alimentado con una co-digestión basada en los sólidos volátiles (SV) de RFV y estiércol de vaca (EV). El EV, recolectado y mantenido a temperatura ambiente, se utilizó como inóculo después de un periodo de estabilización de 15 días y luego como co-sustrato. Los RFV, provinieron del uso doméstico, se recolectaron 5.7 kg, se trituraron, se realizó una mezcla homogénea y se congelaron para su almacenamiento.

La operación incluyó agitación intermitente a 150 RPM durante 1 min, con monitoreo de las siguientes variables cada 5 min: pH, temperatura, humedad, concentración de metano y dióxido de carbono. Además, se registró manualmente el pH de los RFV, la adición de RFV y EV, el inicio de la agitación y la extracción de biogás.

Los datos de monitoreo permitieron identificar patrones, tendencias e interacciones entre las distintas variables. Los datos fueron limpiados y procesados, manteniendo la secuencia temporal, para entrenar el modelo de memoria larga a corto plazo (long short-term memory, LSTM). El modelo LSTM se optimizó mediante el método de búsqueda en cuadrícula. Como resultado, se desarrolló un *soft sensor* basado en datos que incorpora un modelo de inteligencia artificial para predecir el pH en el biodigestor.

ABSTRACT

Anaerobic digestion emerges as an integrated management strategy for organic wastes generated in industrial, urban, and rural environments. Anaerobic digestion stands out as an efficient technology for converting organic wastes into bioenergy, especially those with high moisture content such as fruit and vegetable wastes. However, easy acidification during the hydrolysis of fruit and vegetable wastes presents challenges, thus the implementation of efficient control strategies is necessary. Machine learning models are considered a key tool in the development of anaerobic digestion optimization and control strategies.

A semi-continuous biodigester with an operating volume of 11.5 L was installed. The feed consisted of co-digestion based on volatile solids from the fruit and vegetable wastes, together with cow manure. The cow manure was collected and kept at room temperature. After a 15-day stabilization period, it was used as inoculum and subsequently as co-substrate. The fruit and vegetable wastes, which came from domestic use, was collected in 5.7 kg, crushed, homogeneously mixed and frozen for storage.

The operation included intermittent agitation at 150 RPM for periods of 1 min, with monitoring of the following variables every 5 min: pH, temperature, humidity, methane, and carbon dioxide concentration. In addition, the pH of the fruit and vegetable wastes, the addition of fruit and vegetable wastes and cow manure as feed, as well as, the start of agitation and biogas extraction were manually recorded in the database.

The monitoring data allowed the identification of patterns, trends, and interactions between the different variables. The collected data were cleaned and processed, maintaining the temporal sequence, to train the LSTM model. The LSTM model was optimized by selecting hyperparameters using the grid search method. As a result, a data-driven soft sensor incorporating an artificial intelligence model was developed to predict the pH in the biodigester.

INTRODUCCIÓN

La DA es un proceso de descomposición de sustrato en biogás, compuesto de CH_4 (50%-80%) y CO_2 (30%-50%), se caracteriza por la presencia de un consorcio de microorganismos y la ausencia de oxígeno (Komilis *et al.*, 2017). El biogás producido, mediante la DA, demanda poca energía, por lo que se considera de alta eficiencia energética (Li *et al.*, 2017). El biogás se considera una alternativa a los combustibles tradicionales, además, su uso no genera contaminación atmosférica (Pathak *et al.*, 2009).

Los RFV son generados durante la cosecha, transporte, almacenamiento, estancia en supermercados y sitio de consumo. Debido a sus características fisicoquímicas, los RFV son un potencial sustrato para la DA para generar biogás y biofertilizantes (Agrawal *et al.*, 2023; Shen *et al.*, 2013). La DA se realiza en biorreactores, los cuales proporcionan el entorno necesario para cumplir con los requisitos del bioproceso (Zhong, 2010). Los RFV se hidrolizan fácilmente en la DA, lo que lleva a problemas de acidificación, inhibiendo la actividad de los microorganismos, por lo que se recomienda el uso de cosustratos o soluciones alcalinas para asegurar una operación estable (Shen *et al.*, 2013). Otra posible alternativa para mejorar la operación del digestor usando RFV es la generación de sistemas de monitoreo y control avanzado.

En ese sentido, la inteligencia artificial (artificial intelligence, AI) es una herramienta útil en el desarrollo de modelos para el reconocimiento de patrones, estadísticas y optimización. Recientemente, se han utilizado modelos de AI para predecir el desempeño de la DA a partir de datos del proceso (Long *et al.*, 2021). Las redes neuronales artificiales (artificial neural networks, ANN) las cuales son un modelo no lineal compuesto por al menos tres capas esenciales: la capa de entrada, la capa oculta y la capa de salida. Estas capas están interconectadas por unidades conocidas como neuronas (Kazemi *et al.*, 2020). Las ANN se han empleado para identificar la configuración óptima para la producción de biogás, demostrando una alta precisión en las predicciones, superando a los métodos estadísticos tradicionales, como la

metodología de superficie de respuesta. La configuración óptima identificada a través de la ANN incluyó condiciones específicas de pretratamiento y concentraciones de inóculo (Dahunsi *et al.*, 2017). De Clercq *et al.*, (2019) analizaron la producción de biogás a partir de los parámetros de alimentación utilizando modelos de máquinas de soporte vectorial (support vector machines, SVM). El modelo SVM mapea los vectores de entrada x en un espacio de alta dimensionalidad a través de un kernel, posteriormente, realiza una regresión lineal en este espacio (Kazemi *et al.*, 2020). También se utilizó el modelo de vecinos más cercanos (k-nearest neighbors, KNN). KNN se basa en los patrones de el k -ésimo dato más cercano en el espacio de datos, este método es popular por sus resultados en grandes conjuntos de datos y de baja dimensión (Kramer, 2013). Además, se empleó bosques aleatorios (random forest, RF), el cual es un predictor compuesto por una colección de M árboles de regresión aleatorios, es utilizado en tareas de regresión y clasificación (Biau y Scornet, 2016). El modelo KNN obtuvo el mejor resultado, con un valor de R^2 de 0.87.

Complementando estos avances, Seo *et al.*, (2021) utilizaron una red neuronal recurrente (recurrent neural network, RNN), las RNN son utilizadas en tareas de datos secuenciales. Estas procesan una serie de entrada de elemento en elemento, manteniendo en sus unidades ocultas un "vector de estado" que almacena de forma implícita información histórica de todos los elementos anteriores de la serie (Lecun *et al.*, 2015). En la investigación, fue utilizado como modelo de caja negra para predecir la producción de biogás a partir de parámetros del proceso. Señalan la viabilidad de aplicar el modelo desarrollado para controlar y optimizar procesos biológicos complejos. Dentro de esta categoría de modelos, el modelo conocido como LSTM, que representa un tipo de RNN especialmente diseñado para solventar el problema del gradiente en las RNN tradicionales (Staudemeyer y Morris, 2019). Dado que los datos de bioprocesos suelen tener características de series temporales, los modelos especializados en la previsión de series temporales se han aplicado eficazmente para desarrollar modelos de dependencia temporal en datos biológicos (Lim *et al.*, 2023).

La AI se ha convertido en una herramienta primordial para optimizar la DA, pero aún existen aspectos que requieren mayor investigación y desarrollo. Algunas de las

limitaciones actuales incluyen la escasez de datos para entrenar modelos robustos, la falta de métricas explicativas que permitan comprender el funcionamiento de los modelos y la dificultad para transferir esta tecnología a sectores no especializados (Andrade Cruz *et al.*, 2021; Gupta *et al.*, 2023; Rutland *et al.*, 2023).

Los *soft sensors* son herramientas que utilizan información y mediciones disponibles para estimar valores físicos. En comparación con los modelos mecánicos y de conocimiento, los *soft sensors* basados en datos logran una mayor precisión en la predicción de la dinámica de los procesos industriales, enfrentando así su creciente complejidad (Jiang *et al.*, 2021; Perera *et al.*, 2023). En la actualidad, es posible desarrollar *soft sensors* para la DA utilizando técnicas de AI, lo que permite abordar las variaciones temporales, la no linealidad y las limitaciones presentes en la DA (Yan *et al.*, 2021).

El pH es una variable fácil de medir, que afecta directamente la actividad de los microorganismos y la producción de metano, y está relacionada con el contenido de materia orgánica, por medio de los ácidos grasos volátiles (AGV). Ha mostrado correlaciones significativas con el rendimiento de la DA y, por lo tanto, se utiliza habitualmente en los conjuntos de datos para desarrollar modelos de AI (Jia *et al.*, 2022; Park *et al.*, 2021).

A pesar de que el pH es una variable crítica en el proceso de DA, sólo algunos trabajos han empleado esta variable como *soft sensor* (Waewsak *et al.*, 2010; Zhang *et al.*, 2016). Por lo tanto, este trabajo propuso utilizar un modelo LSTM para desarrollar un *soft sensor* en datos de un biodigestor, manteniendo la secuencia temporal de los datos de monitoreo. Esto permitió desarrollar técnicas capaces de capturar las dinámicas no lineales asociadas con la DA, mejorando así la operación y eficiencia durante la digestión de los RFV.

HIPÓTESIS

Un *soft sensor* basado en datos es capaz de predecir el pH en un biodigestor a escala laboratorio para la producción de biogás.

OBJETIVO GENERAL

1.1 Objetivo General

Desarrollar un *soft sensor* basado en datos incorporando algoritmos de inteligencia artificial para predecir el pH en un biodigestor.

1.1.1 Objetivos específicos

- Construir un biodigestor que opere de forma semicontinua y que sea además flexible al tipo de alimentación considerando digestión o co-digestión.
- Desarrollar un sistema de instrumentación que permita monitorear las variables de operación del biodigestor (pH, temperatura, concentración de metano y concentración de dióxido de carbono).
- Monitorear las variables del biodigestor a través del sistema de instrumentación y construir el modelo de AI basado en la información obtenida como series de tiempo.
- Proponer parámetros iniciales del modelo de AI analizando el sistema para la producción de biogás.
- Optimizar los parámetros del modelo de predicción usando la metodología búsqueda en cuadrícula comparando el desempeño del sistema respecto al sistema óptimo.

REVISIÓN DE LITERATURA

2.1 Digestión Anaerobia

La digestión anaerobia es un proceso de descomposición de sustrato en biogás. La DA es definida en cuatro etapas secuenciales: hidrólisis, acidogénesis, acetogénesis y metanogénesis (ver Figura 1), las cuales dependen de la actividad de un consorcio de microorganismos especializados en cada una de las etapas (ver Cuadro 1) (Mir *et al.*, 2016).

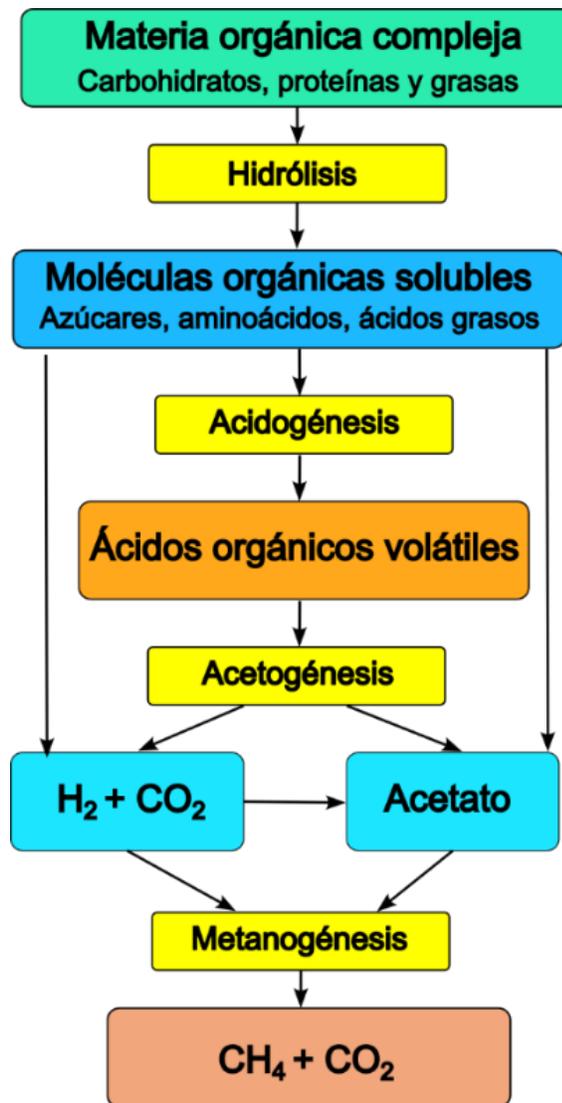


Figura 1. Etapas de la digestión anaerobia.

Cuadro 1. Rol de comunidades microbianas en las etapas de la digestión anaerobia (adaptado de Paritosh *et al.*, 2017).

Etapa	Microorganismos	Genero activo
Hidrólisis	Bacteria hidrolítica	<i>Bacteroides, Lactobacillus, Propionibacterium, Sphingomonas, Sporobacterium, Megasphaera, Bifidobacterium</i>
Acidogénesis	Bacterias sintróficas	<i>Ruminococcus, Paenibacillus, Clostridium, Bacillus, Termomonospora, Bacteriodes, Erwinia, Acetovibrio, Microbispora, Streptomyces</i>
Acetogénesis	Bacterias acetogénicas	<i>Desulfovibrio, Aminobacterium, Acidominococcus</i>
Metanogénesis	Metanógenos (Arqueas)	<i>Methanosaeta, Methanolobus, Methanococcoides, Methanohalophilus, Methanosalsus, Methanohalobium, Halomethanococcus, Methanolacinia, Methanogenium, Methanocullens</i>

En la hidrólisis, las bacterias hidrolíticas secretan enzimas extracelulares que transforman carbohidratos, proteínas y lípidos en azúcares, aminoácidos y ácidos grasos de cadena larga (Li *et al.*, 2011). Los productos de la hidrólisis son absorbidos por los microorganismos presentes en la acidogénesis por medio de la membrana celular, permitiéndoles generar AGV y otros productos (Meegoda *et al.*, 2018). A través de la acidogénesis, la producción de acetato convierte una parte del sustrato para la metanogénesis acetoclástica. Sin embargo, una fracción de AGV aún no está disponible para los microorganismos metanogénicos. La acetogénesis transforma los AGV no disponibles en acetato, generando simultáneamente hidrógeno. La metanogénesis es la última etapa de la DA, se estima que 2/3 de la producción de metano deriva del acetato. La fracción restante proviene del ácido acético que es transformado en metano y dióxido de carbono (Hansen y Cheong, 2019).

2.1.1 Biorreactores

Los biorreactores son tanques o contenedores en los que microorganismos o enzimas libres de células convierten materias primas en productos bioquímicos y/o subproductos de mayor interés (Antolli y Liu, 2012). El biorreactor debe proporcionar un ambiente óptimo que satisface las necesidades del bioproceso. Los parámetros de operación como el pH, oxígeno disuelto, temperatura y concentración de sustrato requieren de ser fáciles de supervisar y controlar (Zhong, 2010). Los biorreactores generan una respuesta a los instrumentos utilizados para regular los parámetros del proceso y corregir cualquier perturbación de sus valores con respecto al punto deseado establecido por el usuario. La cantidad de parámetros que se pueden monitorear y ajustar está limitada por la cantidad de sensores y dispositivos de control integrados en un biorreactor (Abraham *et al.*, 2017; Naga Vignesh, 2020).

2.1.1.1 Configuración de Biorreactores

La elección del biorreactor adecuado para un bioproceso específico es crucial y depende de una evaluación equilibrada de diversos factores críticos, como la transferencia de oxígeno, el mezclado, la estabilidad y la fiabilidad operativas y el costo. El modo de funcionamiento del biorreactor influye significativamente en el rendimiento biológico (Wang y Zhong, 2007). A continuación, se presentan cuatro configuraciones de biorreactores: discontinuo, semi-continuo, flujo tapón y reactor continuo de mezcla perfecta.

Discontinuo

En un reactor discontinuo, al inicio los reactivos son cargados al recipiente, se realiza una mezcla perfecta y se le permite reaccionar durante un tiempo definido. Seguidamente, la mezcla resultante es descargada. La composición de la mezcla en el reactor es uniforme. Se considera una operación de estado inestable (Levenspiel, 1998). En relación con la DA, esta configuración presenta desventajas como la canalización y obstrucción de tuberías debido a las partículas de sustrato de gran

tamaño, requieren mayores volúmenes de operación y los rendimientos de biogás suelen ser bajos. Por otro lado, entre las ventajas, no es necesaria una mezcla continua, agitación o bombeo de la mezcla, lo que permite el ahorro de energía. Además, el costo de capital es bajo (Nizami *et al.*, 2013).

Semi-continuo.

La configuración de un biorreactor semi-continuo es una operación en semi-lotes que utiliza uno o más flujos de alimentación para suministrar nutrientes esenciales para el crecimiento celular y la obtención de productos deseados. La alimentación puede ser intermitente o continua. Los productos son colectados al final del ciclo, lo que provoca un aumento del volumen del cultivo hasta un volumen máximo preestablecido. A partir de este punto, el cultivo se opera en modo discontinuo (Lim y Shin, 2013).

En comparación con un biorreactor discontinuo, el biorreactor semi-continuo presenta una mayor capacidad de tratamiento de sustratos y una mayor producción de biogás. Estos sistemas pueden manejar altos volúmenes de residuos, lo que los hace adecuados para aplicaciones a gran escala. Sin embargo, entre sus desventajas se encuentra la falta de condiciones óptimas de operación definidas, lo que requiere estudios adicionales para optimizar su funcionamiento a gran escala (Zhang *et al.*, 2015).

Flujo tapón

El reactor de flujo tapón es un tanque cilíndrico donde se producen reacciones químicas entre un catalizador revestido en las paredes del reactor y un sustrato añadido. El reactor de flujo tapón mantiene un flujo constante de entrada y salida continua de materia, sin requerir agitación. El sustrato ingresa en forma de “tapón” que se desplaza axialmente a través del reactor, la mezcla de fluido se produce en dirección radial, y genera un flujo turbulento (Jaibiba *et al.*, 2020).

El contenido del digestor de flujo tapón debe ser lo suficientemente espeso como para evitar que las partículas se asienten en el fondo. El contenido de sólidos totales del sustrato debe ser al menos del 15 al 20%. Esto puede requerir sustrato adicional, que también puede ser biodegradable, aumentando la producción de biogás. Los

digestores de flujo tapón comúnmente son cinco veces más largos que anchos, con un tiempo de retención recomendado de 15 a 20 días (Hamilton, 2010).

Reactor continuo de mezcla perfecta

La peculiaridad principal del reactor continuo de mezcla perfecta es el impulsor, el cual ejerce múltiples funciones como: mezcla para la homogeneización, aireación, transferencia de masa y calor (Wang y Zhong, 2007). En la DA, el reactor continuo de mezcla perfecta es ampliamente utilizado debido a su diseño simple y operación sencilla. Proporciona una mayor uniformidad en parámetros como temperatura y concentraciones químicas y de sustrato. Sin embargo, al alimentar el biorreactor con altas concentraciones de sólidos, pueden surgir problemas de obstrucción en las bombas y sedimentación de sólidos en las tuberías, lo que impide una alimentación continua (Usack *et al.*, 2012).

2.1.2 Condiciones de Operación de la Digestión Anaerobia

La producción de biogás se ve afectada por una serie de parámetros que transmiten información sobre el estado del sistema, cuya importancia es relevante para los procesos de producción y optimización (Walid *et al.*, 2021). De forma individual o en conjunto, los parámetros influyen en el desempeño de la producción de biogás; los parámetros relevantes son la materia orgánica (sustratos), las condiciones del proceso (temperatura, pH, presión), el control de reacción (tiempo de retención hidráulica) e inhibición (amoníaco) (Sarker *et al.*, 2019). A continuación, se describen brevemente las condiciones y sus intervalos de operación encontrados en literatura.

2.1.2.1 Sustrato

Los sustratos para la producción de biogás mediante la digestión anaerobia pueden ser colectados de numerosas fuentes como de la industria alimentaria y agrícola (Rowan *et al.*, 2022), plantas de tratamiento de agua (Azarmanesh *et al.*, 2023), desechos y subproductos acuícolas (Choudhury *et al.*, 2022), desechos pecuarios (López-Sánchez *et al.*, 2023), entre otros. Se debe considerar las

características fisicoquímicas del sustrato empleado en el proceso de la DA, ya que influyen en el desempeño de los microorganismos.

Los sustratos pueden ser sometidos a pretratamientos químicos, físicos, biológicos y a combinaciones entre los distintos tipos de pretratamientos con el fin de mejorar la disponibilidad y su degradación (ver Figura 2). Los beneficios de los pretratamientos se ven reflejados en mayores rendimientos de metano, tiempos de retención más cortos, reducción del digestato, control de patógenos, entre otros (Ariunbaatar *et al.*, 2014; Atelge *et al.*, 2020; Khanh Nguyen *et al.*, 2021).

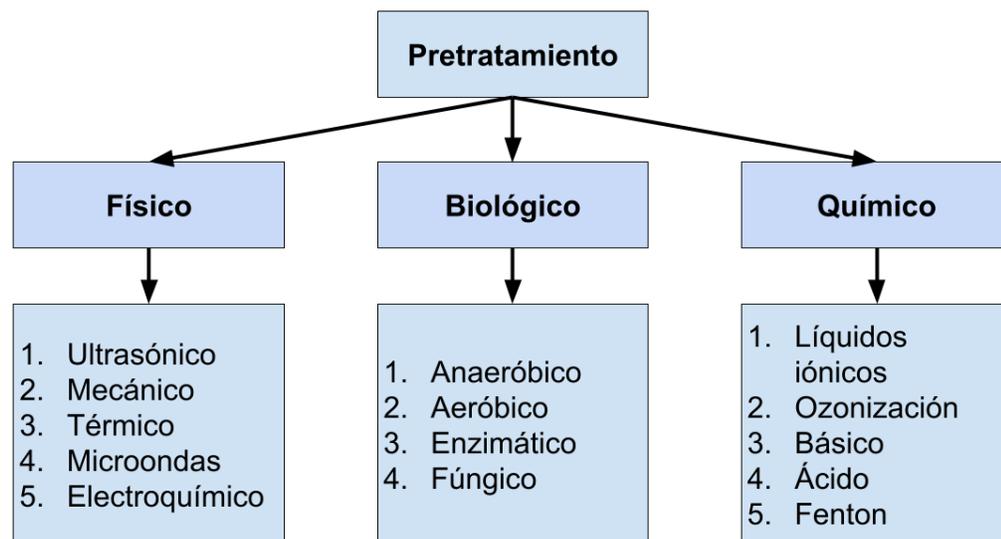


Figura 2. Pretratamientos utilizados en la digestión anaerobia.

La DA puede llevarse a cabo con una fuente de sustrato (mono-digestión) o una mezcla de dos o más fuentes de sustratos (co-digestión). Para realizar una co-digestión eficiente es necesario elegir co-sustratos con características complementarias y proporciones adecuadas, para favorecer un efecto de sinergia positivo. La co-digestión mejora la estabilidad de la DA y aumenta la producción de metano al ampliar la disponibilidad de nutrientes para los microorganismos, aumenta la carga orgánica y reduce el potencial de inhibición por sustancias tóxicas, ajusta el

pH y el contenido de humedad (Kunatsa y Xia, 2022; Pellerá y Gidakos, 2017). Actualmente, se sigue investigando el potencial de diferentes combinaciones de biomasa para la optimización de la digestión anaerobia (ver Cuadro 2).

Cuadro 2. Configuraciones de sistemas de co-digestión.

Sustratos S1/S2	Relación S1:S2	Tipo de biorreactor	Volumen	Rendimiento	Referencia
Estiércol de ganado y estiércol de oveja	1:3	Discontinuo	0.5 L	0.210 L CH ₄ gsv ⁻¹	(Li <i>et al.</i> , 2020)
Aguas residuales municipales y desechos de comida	1:9	Semi-continuo	15 L	0.215 L CH ₄ gsv ⁻¹	(Ounsaneh <i>a et al.</i> , 2021)
Frutas y vegetales y desechos de comida	1:1	Reactor continuo de mezcla perfecta	4 L	0.490 L CH ₄ gsv ⁻¹	(Lin <i>et al.</i> , 2011)
Lodos activados y residuos de pescado	32:1	Discontinuo	0.3 L	0.683 L CH ₄ gsv ⁻¹	(Wu y Song, 2021)

2.1.2.2 pH

Los microorganismos que desempeñan la DA son sensibles al pH. Cuando el pH sale de los rangos de operación afecta negativamente la actividad y el crecimiento de los microorganismos que llevan a cabo cada etapa en el proceso de la DA. Cada etapa de la DA tiene su propio rango de operación de pH (ver Cuadro 3), de acuerdo con la

configuración de los reactores de una sola etapa las condiciones de operación satisfacen las cuatro etapas a la vez (Van *et al.*, 2020).

Cuadro 3. Rangos de pH de acuerdo con la etapa de la digestión anaerobia.

Etapas	pH
Hidrólisis	6.0-8.0
Acidogénesis	5.5-6.5
Acetogénesis	6.0-6.2
Metanogénesis	7.0-7.2

2.1.2.3 Temperatura

La temperatura afecta de diversas formas a la DA: en el crecimiento y diversidad de los microorganismos y en el equilibrio termodinámico de las reacciones químicas (Azevedo *et al.*, 2023). Para microorganismos mesófilos el rango apropiado es de 20°C a 45°C, con un valor de temperatura óptima de 35°C, para microorganismos termófilos su rango adecuado va de los 50°C a 65°C, donde la temperatura ideal es de 55°C (Matheri *et al.*, 2017; Panigrahi y Dubey, 2019).

2.1.2.4 Presión

Las variaciones en la presión de un biorreactor generan complejas relaciones entre las condiciones de operación y la actividad de los microorganismos, se ha documentado que el pH disminuye conforme la presión aumenta, pasando de 7.02 pH en 1.07 bar a 6.5 pH en 8.91 bar, y que la producción de biogás disminuye a presiones de 2.97, 5.95 y 8.91 bar en un 6%, 12% y 24% respectivamente (Chen *et al.*, 2014), de igual forma, afecta la productividad de los organismos metanogénicos disminuyendo su rendimiento en la producción de biogás en presiones reportadas de 0.89 bar (Utami *et al.*, 2021).

2.1.2.5 Tiempo de retención hidráulica

El tiempo de retención hidráulico (TRH) determina el tiempo de estadía de las partículas dentro de un biorreactor, indicando así el tiempo de contacto entre el sustrato y los microorganismos (Reif *et al.*, 2013). El tiempo de retención hidráulico óptimo conlleva altos rendimientos de metano. Tiempos de retención hidráulica muy cortos producen un efecto de lavado del biorreactor, lo que provoca que los microorganismos escapen (David *et al.*, 2019). Por el contrario, TRH demasiado largos reduce la concentración de microorganismos, ya que se genera AGV y amoníaco (Liu *et al.*, 2018).

2.1.3 Biogás

La DA emerge como una estrategia de gestión integral para los desechos orgánicos generados en entornos industriales como en zonas urbanas y rurales. Esta práctica no sólo facilita la disposición eficiente de residuos, también posibilita la recuperación de recursos como bioenergía y digestato rico en nutrientes (Khanal *et al.*, 2023; Pavi *et al.*, 2017).

El biogás, obtenido de la DA, se compone de CH₄ (50%-80%) y CO₂ (30%-50%) (Komilis *et al.*, 2017). El contenido de metano presente en el biogás requiere ser procesado para ser utilizado como fuente de energía, calor y electricidad (Aguilar *et al.*, 2017; Kabeyi y Olanrewaju, 2022). La generación de biogás se realiza a un bajo costo energético, lo que lo posiciona como una opción de gran eficiencia energética. Los coeficientes de retorno de energía sobre la inversión (energy return on investment, EROI) 8.11 ± 1.18 para los residuos ganaderos, 7.29 ± 1.64 para la fracción orgánica de residuos municipales y 11.90 ± 1.23 en los desechos porcinos (Gómez-Camacho *et al.*, 2021; Li *et al.*, 2017). El biogás se plantea como una alternativa a los combustibles convencionales, y destaca por su capacidad para generar menos contaminación atmosférica durante su uso (Pathak *et al.*, 2009). Desde el punto de vista social, el biogás tiene el potencial de fomentar la adopción y la utilización de fuentes de energía limpias en áreas rurales con acceso limitado a la energía (Talevi *et al.*, 2022). Sin

embargo, es necesario mejorar su viabilidad económica, eficiencia y resistencia en comparación con los combustibles fósiles (Caetano *et al.*, 2017).

2.2 Sistemas de Instrumentación

El propósito de los sistemas de instrumentación es obtener un valor numérico de una variable que ha sido medida. Los sistemas de instrumentación se conforman por dispositivos con funciones particulares (Bolton, 2021). Estos instrumentos regularmente son:

1. Sensores (termómetro, barómetro, entre otros)
2. Procesadores de señal (microcontrolador)
3. Registro de datos (presentación visual, base de datos)

Para la selección adecuada de instrumentos es necesario reconocer los requerimientos del sistema considerando factores como la sensibilidad, tiempo de respuesta, exactitud, calibración y mantenimiento (Webster y Eren, 2018).

2.2.1 Sistemas de Monitoreo en la Digestión Anaerobia

El monitoreo de un biorreactor es una estrategia efectiva para asegurar la estabilidad de la DA. La estrategia de monitoreo es comúnmente basada en los parámetros del proceso de la DA, como la temperatura, pH, AGV, de esta forma se obtiene una vista general del estado del sistema, lo que permite detectar patrones y extraer información de la operación (Wu *et al.*, 2021).

El análisis fuera de línea o en laboratorio frecuentemente se relaciona con errores de muestreo, sesgos y análisis inadecuados (Drosg, 2013). La recopilación de datos es lenta lo que llevaría a una acción correctiva tardía y un eventual fallo en el biorreactor, por lo tanto, estudios recientes se enfocan en el desarrollo de técnicas de monitoreo en línea (Nguyen *et al.*, 2015). Los métodos más efectivos de monitoreo deben ser realizados in situ o en línea, de forma automática y continua, implicando que la detección de parámetros se lleva a cabo directamente mientras el biorreactor está en funcionamiento (Cruz *et al.*, 2021; Wu *et al.*, 2019).

Los instrumentos destinados al monitoreo en línea y control de bioprocesos deben poseer atributos específicos que los hagan aptos para su aplicación. Es fundamental que los sensores mantengan su calibración, asegurando un sólido equilibrio entre la señal y el ruido, al tiempo que exhiban elevada especificidad y selectividad (Rösner *et al.*, 2022).

2.3 Inteligencia Artificial

La AI es un enfoque de la computación que busca imitar la capacidad cognitiva humana a través del conocimiento estructurado simbólicamente para solucionar problemas que son desafiantes mediante métodos tradicionales (Salehi y Burgueño, 2018). El aprendizaje automático (machine learning, ML) se considera un componente de la AI, que realiza reconocimientos automatizados de patrones relevantes en conjuntos de datos. A su vez, el aprendizaje profundo (deep learning, DL), es una subcategoría del ML especializado en grandes conjuntos de información (Shalev-Shwartz y Ben-David, 2014; Woschank *et al.*, 2020).

2.3.1 Aprendizaje Profundo

El DL se basa en el concepto de las redes neuronales biológicas. Cuando se recibe nueva información se compara con la información conocida para darle significado. El término profundo hace referencia al número de capas de una ANN. La capa de entrada es donde se reciben los datos, la capa oculta extrae la relación entre los datos y la capa de salida otorga el resultado del análisis de los datos. Una ANN profunda se caracteriza por tener un gran número de capas ocultas (Jakhar y Kaur, 2020).

El DL comprende modelos como las ANN, redes neuronales convolucionales (convolutional neural network, CNN), RNN y autocodificadores (Khaki *et al.*, 2020; Michelucci, 2022) y sus aplicaciones pueden ser la visión artificial, predicciones, análisis semántico, procesamiento de lenguaje natural, recuperación de información (Shinde y Shah, 2018).

Independiente al objetivo de integración de AI, los modelos de AI requieren datos del proceso de la DA. Estas fuentes de datos incluyen datos reales obtenidos de biodigestores, plantas de tratamiento y otras fuentes, o datos simulados obtenidos de modelos matemáticos (Bo Yang *et al.*, 2024; Mendiola-Rodriguez y Ricardez-Sandoval, 2022).

2.3.1.1 Long Short-Term Memory

El modelo de memoria larga a corto plazo (LSTM) es un tipo de RNN, diseñada para solventar el problema del gradiente presente en las RNN tradicionales. Esto se logra mediante una nueva arquitectura que incorpora células de memoria (*Memory cells*) y unidades de compuerta (*Gate units*) (Hochreiter y Schmidhuber, 1997). En la Figura 3 se muestra el cálculo interno para una célula en el modelo LSTM.

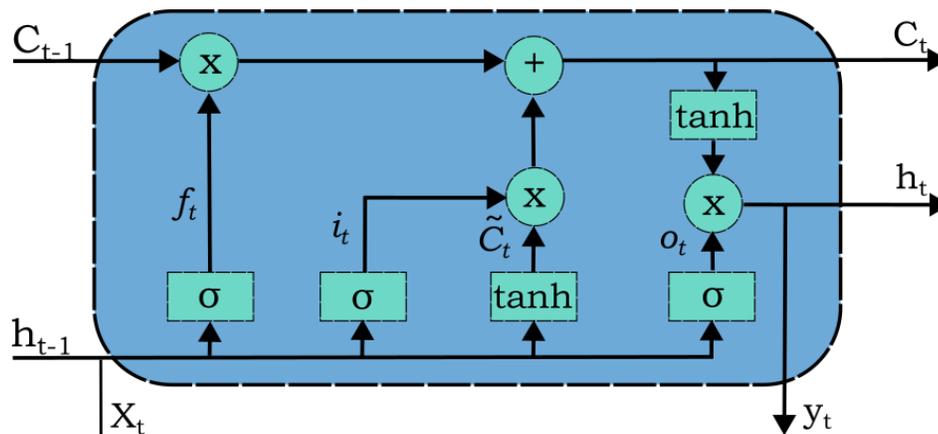


Figura 3. Diagrama del funcionamiento de un modelo *Long Short-Term Memory*.

Las células de memoria incluyen cuatro unidades de compuerta: *olvido* (f_t), *entrada* (i_t), *actualización* (\tilde{C}_t) y *salida* (o_t). La función del modelo LSTM es mantener un error constante mientras retienen datos relevantes y eliminan los irrelevantes (Hasan, 2023). He *et al.*, (2019) describen los cálculos dentro de la célula de memoria de la LSTM de la siguiente forma:

- Se aplica la función sigmoide en el conjunto de datos de entrada (x_t) y el estado oculto previo (h_{t-1}) para determinar qué información debe ser eliminada del estado de la célula, de acuerdo con la siguiente ecuación:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (E1)$$

- Para determinar la información nueva que se almacena en el estado de la célula se realizan dos pasos. En el primer paso la función sigmoide, $\sigma(\cdot)$, determina qué información preservar en el estado de la célula de acuerdo con la ecuación E2, y en el segundo paso se aplica la función $\tanh(\cdot)$ en x_t y h_{t-1} para obtener los valores candidatos a la actualización, \tilde{C}_t , siguiendo la ecuación E3.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (E2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (E3)$$

- La actualización del estado previo de la célula, C_{t-1} , a un nuevo estado de la célula, C_t , se realiza siguiendo la ecuación E4, donde el estado previo de la célula es multiplicado por f_t para eliminar la información seleccionada y se suma i_t multiplicado por \tilde{C}_t .

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (E4)$$

- Después se calcula la compuerta de salida, o_t , a través de la aplicación de la función sigmoide a h_{t-1} y x_t siguiendo la ecuación E5. Posteriormente se calcula el estado oculto aplicando la función tangente hiperbólica al nuevo estado de la célula multiplicado por la compuerta de salida siguiendo la ecuación E6.

$$o_t = \sigma(W_o * [h_{t-1}, x_t] + b_o) \quad (E5)$$

$$h_t = o_t * \tanh(C_t) \quad (E6)$$

Donde W_f, W_i, W_c, W_o representan los pesos de matrices, b_f, b_i, b_c, b_o denotan el sesgo de los vectores. La función sigmoide $\sigma(\cdot)$ es calculada con la ecuación E7 y la función tangente hiperbólica $\tanh(\cdot)$ con la ecuación E8, ambas funciones son utilizadas como funciones de activación.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (E7)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (E8)$$

El modelo LSTM se ha utilizado ampliamente en diversas ramas de la ingeniería para realizar predicciones de precios de productos agrícolas (Gu *et al.*, 2022), predecir variables clave relacionadas con el fallo en procesos químicos (Bai *et al.*, 2023), generar secuencias genómicas de fagos (Ataee *et al.*, 2022), así como en tareas de optimización (Yilmaz y Büyüktaktın, 2023), control (Liu *et al.*, 2023) y como *soft sensor* (Ren *et al.*, 2022).

2.3.2 Inteligencia Artificial en la Digestión Anaerobia

Los modelos de AI, como el ML y DL, proveen numerosas ventajas en la DA (Onu *et al.*, 2023). Los modelos de AI pueden procesar datos ruidosos, incertidumbres, alta dimensionalidad, sistemas no lineales y problemas mal definidos (Venkatasubramanian, 2019). Estas características están presentes en la DA, donde la compilación de una gran cantidad de datos precisos es complicada. El resultado del modelo podría verse influido por los algoritmos y metodologías empleados durante su construcción, lo que requiere un profundo conocimiento de la AI y la DA (Onu *et al.*, 2023; Wang *et al.*, 2023).

La implementación de AI en la DA tiene varios objetivos, como la predicción de variables del proceso, la integración de estrategias de control y optimización, o el desarrollo de un *soft sensor* y modelos basados en datos (Ahmad *et al.*, 2024; Kazemi *et al.*, 2021; Li *et al.*, 2022; Mendiola-Rodriguez y Ricardez-Sandoval, 2022; Waewsak *et al.*, 2010).

La aplicación de la AI para mejorar el proceso de la DA se ha establecido como una estrategia consolidada, sin embargo, aún persisten áreas de oportunidad que continúan en desarrollo. Gupta *et al.*, (2023), reportaron a la carencia de métricas explicativas en el desarrollo de modelos de AI, como cuantificación de la dependencia parcial, importancia de características por permutación y explicaciones aditivas de

Shapley (*Shapley additive explanations*, SHAP). Estas métricas son de importancia para la comprender la correlación y relación entre las variables predictoras y las variables predichas. Andrade-Cruz *et al.*, (2022), señalaron la restricción relacionada con la falta de datos de entrenamiento, lo que dificulta el entrenamiento efectivo de un modelo en muchos casos. También resaltaron la dificultad que para comparar diferentes configuraciones de DA ocasionado por las variaciones de las condiciones operativas. Rutland *et al.*, (2023), estudiaron el desarrollo de modelos de AI accesibles para el usuario final, requiriendo una mínima cantidad de codificación, al mismo tiempo que pueda identificar la configuración adecuada para un bioproceso específico. En esta perspectiva, la AI puede contribuir a la bioeconomía circular, donde los residuos y subproductos son transformados en bioenergía y productos biológicos de valor agregado.

2.4 Soft Sensors

Los *soft sensors* estiman o predicen valores físicos a partir de la información y mediciones disponibles. A diferencia de los sensores físicos, los *soft sensors* son implementados en sistemas integrados o en sistemas informáticos basados en software (Jiang *et al.*, 2021). Los *soft sensors*, basados en datos, son una respuesta ante la creciente complejidad de los procesos industriales, donde los *soft sensors* basados en modelos mecánicos y de conocimiento no realizan predicciones satisfactorias (Sun y Ge, 2021). Al basarse en datos reales, los *soft sensors* pueden modelar la dinámica del proceso con mayor precisión, logrando un mayor rendimiento en sus predicciones (Perera *et al.*, 2023).

Los *soft sensors* desarrollados con modelos de DL tienen mayor precisión en las predicciones, mayor capacidad de autoaprendizaje, adaptación, ajuste no lineal y mayor generalización ante la complejidad de la DA, en comparación con *soft sensor* desarrollados con modelos regresivos, de ML, modelos tradicionales y de ANN (Wang *et al.*, 2021; Yan *et al.*, 2021).

MATERIALES Y MÉTODOS

3.1 Plan de Trabajo

La Figura 4 representa el plan de trabajo para el desarrollo del *soft sensor*. Esta investigación se desarrolló en tres etapas. La primera etapa incluye la construcción del biorreactor, junto con la caracterización del inóculo y el sustrato. La segunda etapa comprende el desarrollo del sistema de monitoreo, donde se seleccionaron los sensores, se realizó su circuito y la configuración del registro de los datos. La tercera etapa se basó en el análisis de los datos obtenidos del sistema de monitoreo, analizando la relevancia de las variables y realizando una optimización de hiperparámetros al modelo LSTM. Finalmente, el *soft sensor* fue evaluado con los datos de prueba.

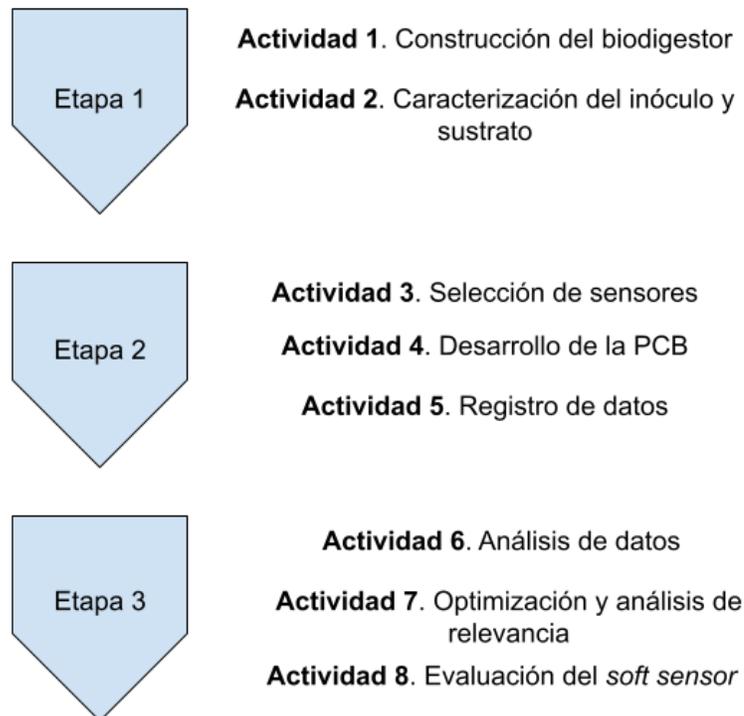


Figura 4. Etapas del plan de trabajo

3.2 Biodigestor

El biodigestor fue construido bajo el fundamento de un biorreactor semicontinuo con agitación. Como restricciones se consideraron: 1) materiales de rápida adquisición, seguros y de fácil manipulación, 2) impermeables para evitar fugas de gases y líquidos, 3) resistentes ante las vibraciones de la agitación, la presión ejercida por los líquidos y gases y sustancias corrosivas, y 4) fácil almacenamiento y movilidad.

Considerando los puntos anteriormente mencionados: el biodigestor empleado en este estudio fue un recipiente de poliestireno con una capacidad de 18.92 L, construido específicamente para esta investigación. El biodigestor en la parte superior tiene el puerto de la alimentación de sustratos, una conexión dedicada para la instalación de sensores y un dispositivo mecánico de agitación y el puerto de salida del biogás. Además, el equipo tiene otras dos salidas: destinadas a la extracción de lodos. La salida de muestreo está ubicada lateralmente al fondo del recipiente. Mientras que la compuerta de descarga del lodo está ubicada lateralmente al fondo de recipiente, pero con una configuración de tubería que asegura por mecánica de fluidos que el volumen operativo efectivo del biodigestor en un valor de 11.5 L. Este diseño permite tener un intervalo de TRH de 43 a 136 días acorde a la tasa de alimentación empleada. La alimentación de los RFV y el EV se mantuvo baja debido a la inestabilidad que presentó el biodigestor en el arranque, al no ser modificada ocasionó un TRH de 136 días. El biodigestor se localizó en el Laboratorio de Biotecnología Microbiana de la Facultad de Agronomía, manteniéndose a temperatura ambiente con un promedio de 23.16 °C. El sistema de agitación consistió en un motor de corriente alterna (CA) de ¼ HP, una transmisión y un agitador de paleta. La agitación del biodigestor se realizó a 150 RPM durante un periodo de 1 min.

Para asegurar la fijación de los sensores dentro del biodigestor se diseñaron y fabricaron piezas con impresión 3D que funcionan como soporte para los sensores. El biodigestor fue instalado sobre una base realizada con perfil tubular rectangular, para la estructura, y melamina para soportar el biodigestor. La base también cuenta con un soporte para la instrumentación y un soporte para el motor de la agitación. La Figura

5 representa el diagrama de conexiones y tuberías. El biodigestor se presenta en la Figura A 1 en la sección de anexos.

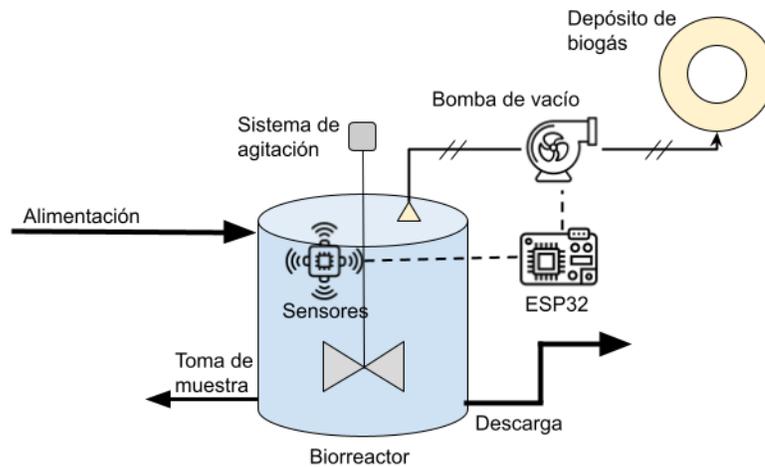


Figura 5. Diagrama de conexiones y tuberías.

3.3 Inóculo

El inóculo utilizado en el estudio fue EV recolectado el día 23 de septiembre de 2023 del establo lechero de la Facultad de Agronomía de la UANL en el municipio de Marín, Nuevo León. Se recolectaron 17 L de EV que se dividieron en dos recipientes mantenidos a temperatura ambiente. En cada recipiente para mejorar su manipulación, se adicionaron 3 L de agua debido a su alta viscosidad. El pH del agua añadida al estiércol fue de 8. Tras un periodo de estabilización de 15 días, el inóculo se utilizó en el sistema experimental como inóculo.

Posteriormente, el EV fue utilizado como co-sustrato. Se instaló una válvula unidireccional tipo *Air lock* para permitir la salida del gas generado en los recipientes. En este periodo, no se añadieron sustratos al EV. El recipiente que contenía el EV era agitado previo a su uso como co-sustrato. No se presentaron contaminantes, malos olores o apariencias desagradables.

3.4 Sustrato

El sustrato empleado consistió en una mezcla de RFV provenientes del uso doméstico. Los RFV fueron inicialmente congelados hasta acumular una cantidad significativa. Posteriormente, se pesaron, trituraron y homogenizaron. La mezcla resultante fue dividida en bolsas plásticas de 250 gr cada una, las cuales se congelaron nuevamente hasta su uso, donde fueron descongeladas. Los RFV recolectados sumaron un total de 5.7 kg, las proporciones detalladas se muestran en el Cuadro 4.

Cuadro 4. Proporciones másicas del sustrato

Residuo	%	Residuo	%
Piña	8.5	Chícharo	1.3
Pepino	1.3	Jícama	10.4
Zanahoria	0.6	Cebolla	2.2
Manzana	0.3	Calabaza	1.2
Plátano	4.1	Calabacita	1.2
Aguacate	4.3	Fresa	6.8
Lechuga	6.4	Papa	0.7
Tomate	12.9	Nopal	5.1
Champiñón*	1.9	Alfalfa	3.7
Melón	18.4	Uva	8.7

*Aunque el champiñón no es una fruta o verdura. Al ser un residuo de la cocina doméstica fue considerado parte de la mezcla de RFV.

La caracterización del inóculo y el sustrato se presenta en el Cuadro 5. Los sólidos totales, volátiles y cenizas se determinaron siguiendo el protocolo descrito en APHA/AWWA/WEF (2005), el porcentaje de humedad se determinó mediante la norma mexicana NMX-AA-16-1984, (1992), mientras que el pH se midió conforme a la normativa NMX-AA-25-1984, (1992). La viscosidad se evaluó utilizando un viscosímetro Brookfield LVDVE con el rotor S63 en RFV y S62 en EV a 30 RPM.

Cuadro 5. Caracterización del estiércol y frutas y verduras.

Propiedad	Estiércol	Frutas y verduras
ST (g L ⁻¹)	7.51	9.56
SV (g L ⁻¹)	6.3	9.30
Cenizas (g L ⁻¹)	1.18	0.26
Humedad (%)	17.18	10.20
pH	6.6	4.9
Viscosidad (cP)	466	1,377.33
Densidad (g mL ⁻¹)	0.97	1.404

3.5 Instrumentación y Monitoreo

El sistema de instrumentación y monitoreo se desarrolló con un funcionamiento semi-automático. Los sensores empleados y su respectiva variable de medición son presentados en el Cuadro 6. Los sensores fueron programados para medir sus respectivas variables cada 5 min, la medición se almacena en la base de datos de forma automática.

Cuadro 6. Sensores y sus variables de medición

Sensor	Variable (unidad)
DS18B20	Temperatura (°C)
MQ-4	Concentración de Metano (ppm)
MQ-135	Concentración de Dióxido de Carbono (ppm)
Sonda de pH	pH (-)

Además de los sensores, se instaló una bomba de vacío con capacidad de 1 L min⁻¹ para la extracción del biogás. La bomba es encendida manualmente presionando un botón y su encendido es registrado automáticamente en la base de datos. Adicionalmente, parte del monitoreo es ingresar a la base de datos de forma manual la cantidad de sólidos volátiles añadidos del EV y RFV (g L⁻¹), el pH del sustrato de alimentación añadida (pH), y la agitación (valor de 1 para inactiva y de 2 para activa).

La placa de circuito impreso (printed circuit board, PCB) (ver Figura 6) fue diseñada para obtener un sistema compacto y de mayor portabilidad. La PCB está conformada por un soporte para el microcontrolador, seis conexiones analógicas para sensores, seis LEDs, un botón, dos relevadores y dos terminales 12 V destinadas para dispositivos mecánicos como bombas de vacío o peristálticas.

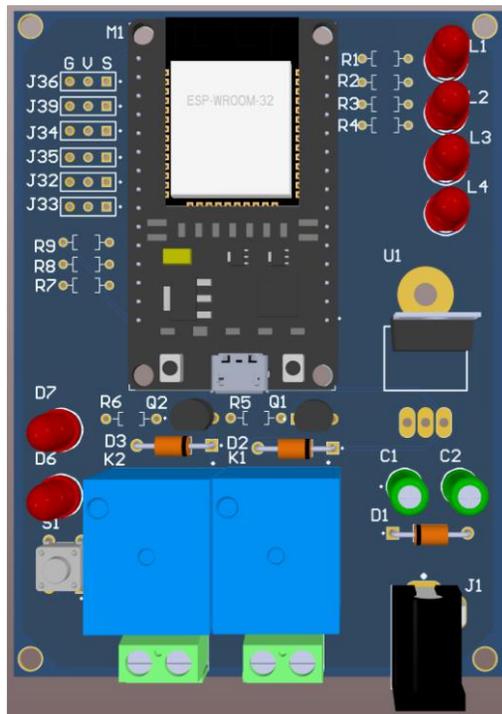


Figura 6. PCB para el monitoreo del biodigestor.

Los datos de medición de los sensores de pH, temperatura del efluente, concentración de metano y dióxido de carbono fueron recopilados en intervalos de 5 min por el Esp32-WROOM-32 y enviados a *Firestore Realtime Database* para su posterior procesamiento. La bomba de vacío para la extracción de biogás fue controlada por el Esp32. Al presionar el botón, la bomba se encendía durante 60 s, y su activación se registraba automáticamente en la base de datos. La Figura 7 presenta el diagrama de flujo del código realizado en el entorno de desarrollo integrado de Arduino.

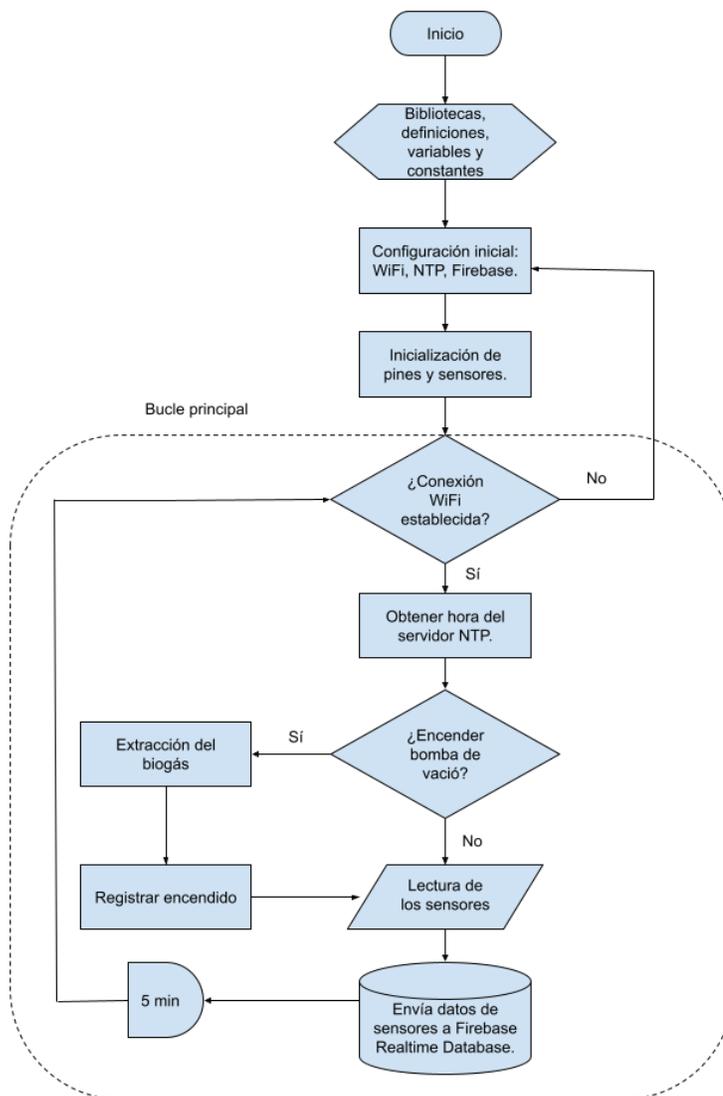


Figura 7. Diagrama de flujo del código del Esp32.

3.6 Protocolo de Operación

El sistema opera en configuración tipo semi-continuo. La alimentación fue realizada cada tercer día con base en los sólidos volátiles del EV y RFV. La agitación fue encendida antes de la alimentación para romper las burbujas de gas disueltas en el medio y se extrajo el biogás. Una vez alimentado, el tanque es agitado nuevamente para homogenizar el medio.

Los sensores fueron calibrados de acuerdo con las indicaciones de los fabricantes y recibieron mantenimiento cada 15 días. Al detectar un funcionamiento inadecuado en alguno de los sensores, se reemplazó.

3.7 Procesamiento y Análisis de Datos de la Digestión Anaerobia

Los datos recopilados por el sistema de instrumentación y monitoreo permitieron generar una base de datos que comprende un total de 4,608 pasos en el tiempo, correspondientes al periodo del 15 al 31 de marzo de 2024. Los datos presentaron ruido y valores atípicos, como valores infinitos y no numéricos. Para ajustar la dimensión temporal de los diferentes tipos de medición, se aplicaron estrategias de sustitución. Por lo tanto, los datos fueron analizados y procesados manteniendo la secuencia temporal. Además, los datos fueron manipulados con el método del rango intercuartílico para eliminar valores atípicos, para minimizar el ruido se aplicó una media móvil, por último, valores infinitos y no numéricos fueron reemplazados por la media.

Como parte del análisis de datos, se realizó un escalamiento utilizando el método de escalado de mínimos y máximos de acuerdo con la ecuación E9.

$$X_{escalado} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (E9)$$

Con el fin de visualizar datos, detectar patrones y una comprensión más clara, los datos fueron graficados de forma lineal y en diagramas de caja para visualizar la dispersión y variabilidad de los datos.

3.8 Análisis de Relevancia de las Variables

Los análisis de coeficientes de correlación de Pearson y Spearman fueron utilizados como métodos de filtrado para la selección de variables (Chandrashekar y Sahin, 2014). El método establece que las variables con correlaciones nulas sean eliminadas, de forma que sólo las variables relevantes son mantenidas en el conjunto

de datos. Tras aplicar estos métodos, se observó que incluso variables con correlaciones bajas y nulas podrían tener valor en ciertos contextos. Por lo tanto, se evaluó la importancia de cada variable antes de tomar la decisión final sobre su inclusión en el *soft sensor*.

3.9 Soft Sensor – Long Short-Term Memory –

Las secuencias de datos de entrada para la red se definieron en seis unidades, con una unidad de salida. Con el objetivo de minimizar el error del modelo, se implementó una técnica de ajuste de hiperparámetros. La estrategia utilizada fue la búsqueda en cuadrícula, considerando los hiperparámetros detallados en el Cuadro 7. Para evitar el sobreajuste del modelo, se emplearon técnicas como *EarlyStopping*, y validación cruzada. Los datos fueron divididos conservando la continuidad temporal en 60% destinado al entrenamiento, 20% para la validación y 20% para la prueba, (Figura 8).

Cuadro 7. Hiperparámetros utilizados en la búsqueda por cuadrícula.

Neuronas	Función de activación	Optimizador	Tamaño de lote	Épocas	Abandono recurrente
32	Relu	Adam	16	20	0.1
64	Tanh	SGD	32	50	0.2
	Sigmoide	RMSProp		100	

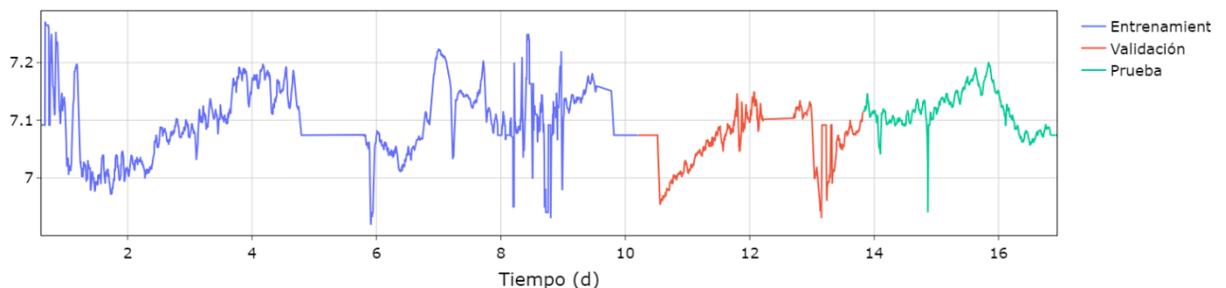


Figura 8. Distribución de datos de entrenamiento, validación y prueba

La evaluación de los modelos se realizó utilizando dos indicadores: el error cuadrático medio (mean square error, MSE) y el error absoluto medio porcentual (mean absolute porcentual error, MAPE) calculados mediante la ecuación E10 y E11, respectivamente.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (E10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} * 100 \quad (E11)$$

Donde y_i representa los valores reales y \hat{y}_i los valores predichos.

RESULTADOS Y DISCUSIÓN

4.1 Desempeño y Análisis de la Digestión Anaerobia

La concentración de metano (Figura 9), presentó valores máximos de 15,000 ppm y mínimas de 113 ppm y la concentración de dióxido de carbono (Figura 10) presentó valores máximos de 2407 ppm y mínimos de 27 ppm. De acuerdo con los valores promedios de la concentración de los gases, únicamente considerando metano y dióxido de carbono, la relación fue 89% de metano y 11% de dióxido de carbono.

Del día 4 al día 10 la concentración de los gases presentó bajas concentraciones, esto pudo deberse a la disminución de temperaturas ($\leq 20^{\circ}\text{C}$) presentes en los días 4, 5 y 6. El día 5 se realizó un mantenimiento de emergencia por una falla en el sensor de pH ocasionada por la adherencia de sustrato en el electrodo. Ambas concentraciones de gas presentaron aumentos graduales en la concentración al añadir sustrato al biodigestor, al encender la agitación la concentración de los gases aumenta drásticamente, producto de la ruptura de las burbujas atrapadas en el medio, el caso contrario puede observarse con la extracción del biogás, donde las concentraciones de los gases disminuyen.

Pandian *et al.*, (2021) en un biodigestor a escala laboratorio de 2 L alimentado con estiércol de vaca y residuos vegetales detectó concentraciones máximas de 1100 ppm y mínimas de 100 ppm de metano. El TRH fue de 30 días, la temperatura se mantuvo en un rango de 28 a 45 °C y el pH oscilo entre valores de 6 y 7.5. Al-Talib *et al.*, (2024) detectó concentraciones máximas de dióxido de carbono de 980 ppm y mínimas de 877 ppm en un biodigestor a escala laboratorio alimentado con estiércol animal y desechos de comida, mantenido a una temperatura de 31°C.

El biogás fue extraído por medio de una bomba de vacío y almacenado en un dispositivo toroide. La bomba de vacío tiene una capacidad de 1 L min^{-1} . Dado que la bomba fue encendida 8 veces durante el análisis por un periodo de un minuto, se estima una producción de biogás de 0.5 L d^{-1} , con un rendimiento de 0.671 L biogás g SV^{-1} . La producción de biogás acumulada se presenta en la Figura 11.

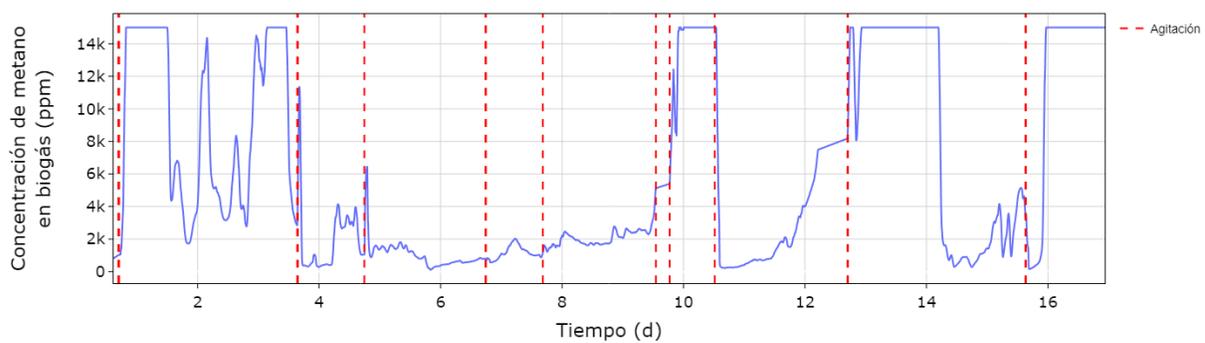


Figura 9. Concentración de metano.

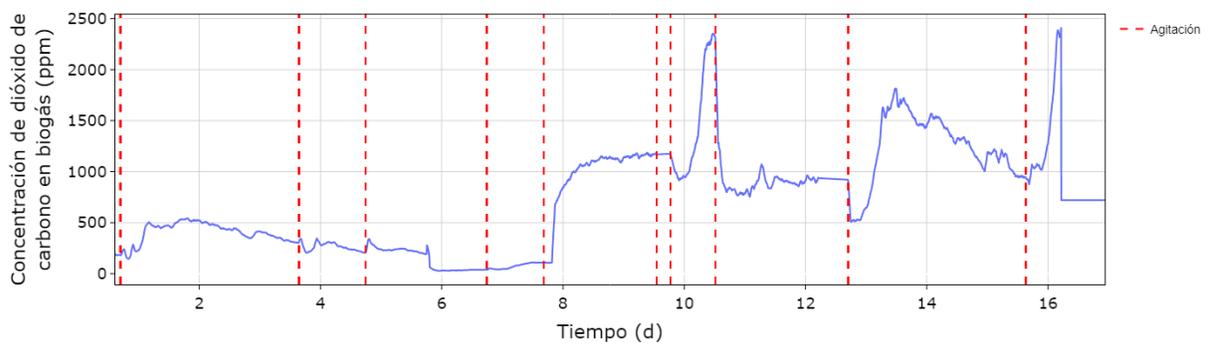


Figura 10. Concentración de dióxido de carbono.

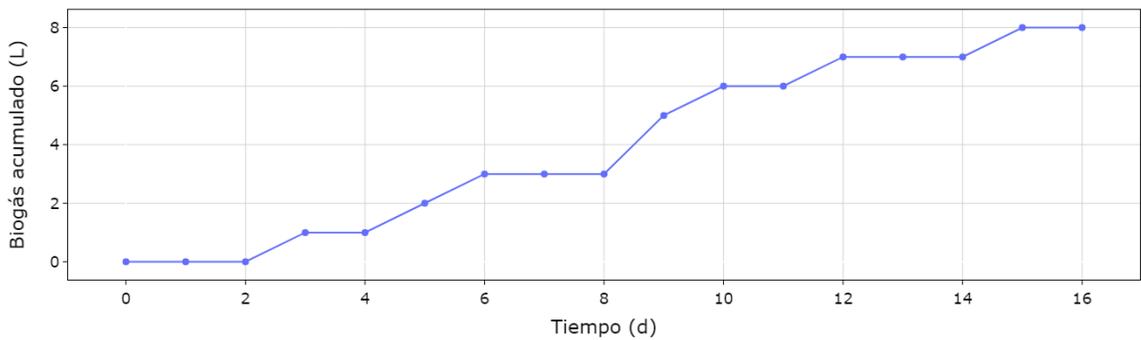


Figura 11. Producción de biogás acumulado.

El biorreactor al ser alimentado presentó una respuesta rápida ante la acidez de los RFV, alcanzando valores mínimos de pH de 6.92 y recuperándose en un corto periodo (Figura 12). A pesar de las oscilaciones de pH causadas por la alimentación, el pH se mantuvo estable en un rango de 6.92-7.27, ya que no mostró una tendencia positiva o negativa. Se buscó generar una leve tendencia negativa variando la cantidad de alimentación de RFV y EV, sin embargo, lograr esta tendencia no fue posible debido a la flexibilidad y resiliencia que presentó el biorreactor tras una operación prolongada en parámetros de operación estables y una carga orgánica alimentada de $0.075 \text{ g SV d}^{-1} \text{ L}^{-1}$. Este comportamiento oscilante, así como la estabilidad del pH en el rango de 7.64-8.29 a pesar de las concentraciones altas de AGV fue reportado por Jia *et al.*, (2022).

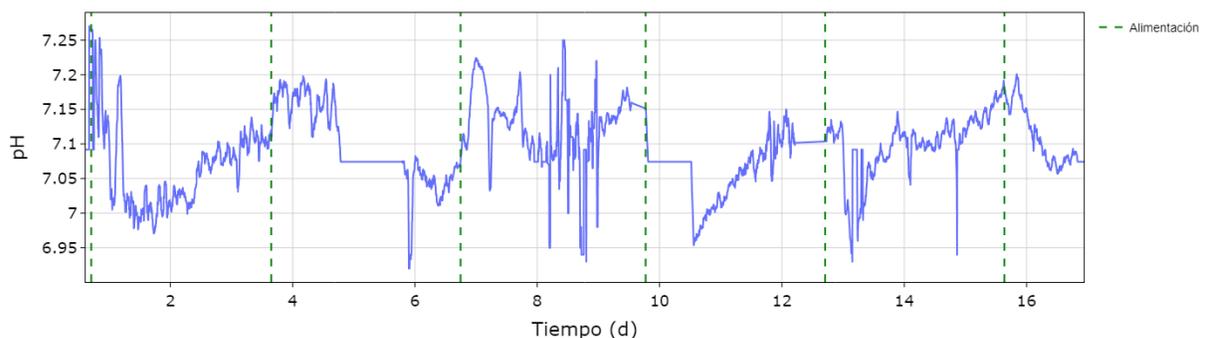


Figura 12. Comportamiento de pH.

La temperatura del biorreactor se muestra en la Figura 13. La temperatura promedio para el periodo analizado fue de 23.16 °C. Las lecturas de la temperatura se mantuvieron estables a lo largo del tiempo, sin problemas en el sensor, excepto por un corte eléctrico que ocurrió entre el día 12 y 13. A partir del día 4 al día 6 se presentó un descenso en la temperatura, registrando una temperatura mínima de 18.54 °C. Esta variación causó una dispersión en los datos, resultando en la necesidad de omitir el método de rango intercuartílico en el análisis de la temperatura del efluente. Aunque el valor promedio de la temperatura se mantuvo en el rango mesofílico con valores entre 20-26 °C, no alcanzó el valor óptimo de 35 °C reportado Matheri *et al.*, (2017).

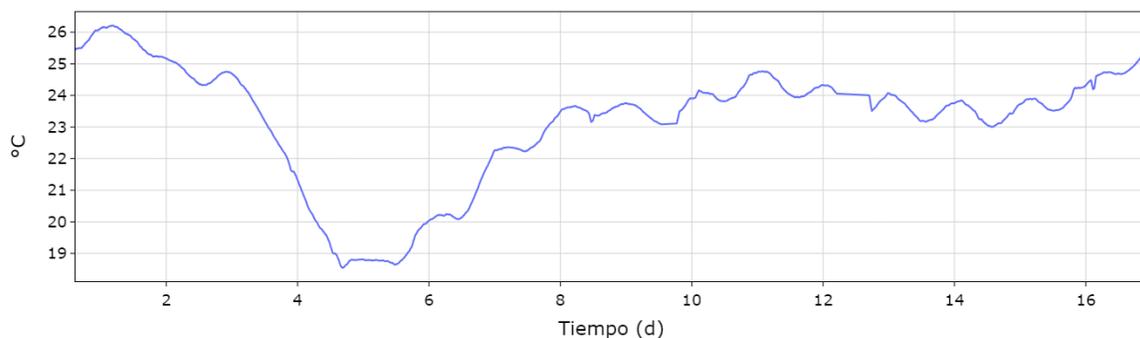


Figura 13. Temperatura del biorreactor.

Los datos obtenidos durante el periodo de análisis para las variables monitoreadas de la DA fueron normalizados para realizar una gráfica de cajas. En la Figura 14 se aprecia la distribución de los datos por medio de sus cuartiles. El pH presentó una distribución casi uniforme y simétrica, con múltiples datos atípicos en ambos extremos. El metano mostró un rango intercuartílico extendido debido a que las concentraciones disminuyen durante su extracción y aumentan cuando se genera y acumula, lo que ocasiona una alta dispersión en los datos. El dióxido de carbono presentó una distribución asimétrica, con la mayor cantidad de datos concentrados en el rango intercuartílico, pero el bigote superior indica la presencia de valores altos, además de la presencia de valores atípicos en el extremo superior. Por último, la temperatura se destaca por la alta concentración de valores atípicos en el extremo inferior, debido a la presencia de bajas temperaturas en un corto periodo.

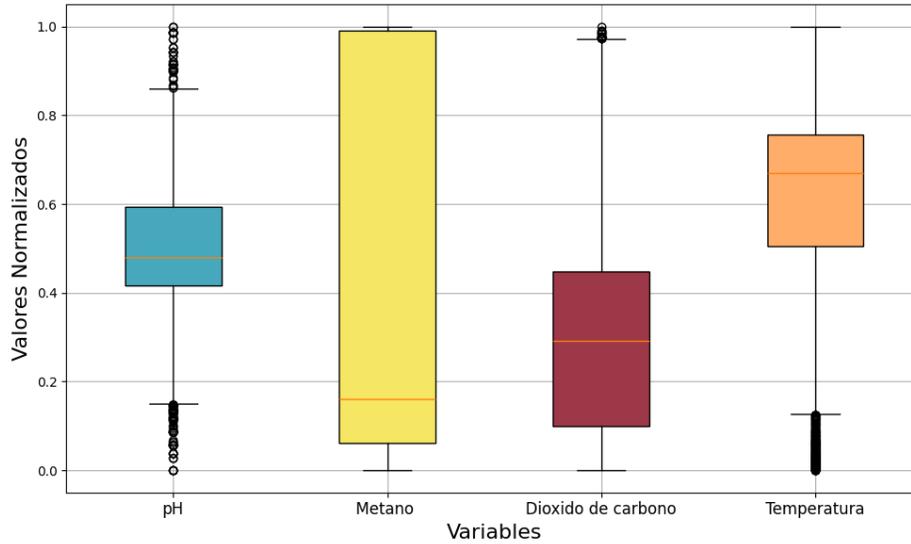


Figura 14. Diagrama de caja de las variables monitoreadas.

La Figura 15 muestra los valores para la alimentación EV y RFV, así como el valor de pH para los RFV, la extracción de gas y la agitación. La alimentación de EV y de RFV fueron realizadas y registradas en la base de datos de forma manual, incluyendo el pH de los RFV. Aunque la alimentación se realiza en un punto en el tiempo, el valor de SV y pH se mantiene constante hasta que se realiza un cambio en el valor registrado. La agitación y extracción de biogás se registraron con el valor de dos cuando están activas y uno cuando se mantiene apagado.

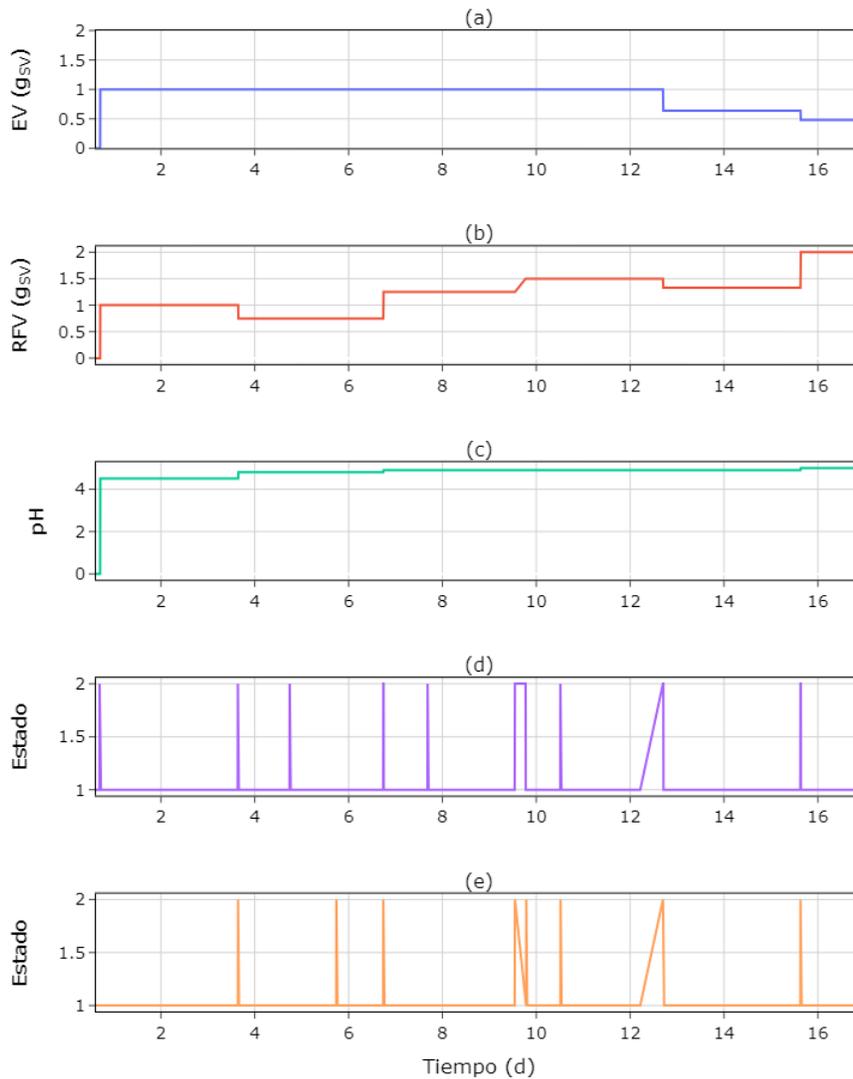


Figura 15. Alimentación con estiércol (a), alimentación con RFV (b), pH de los RFV (c), extracción de gas (d) y agitación (e).

4.2 Ajuste y Rendimiento del Soft Sensor

4.2.1 Selección de las Variables de Entrada

La Figura 16 muestra la matriz de correlación con el método de Pearson, el pH presentó coeficientes de correlación débiles con el EV de -0.15, con la temperatura de -0.14 y el metano de -0.14. Con el resto de las variables, la correlación se presentó nula. La temperatura mostró una correlación positiva con el dióxido de carbono y el

metano de 0.41 y 0.48, respectivamente, lo que sugiere que un aumento en la temperatura incrementa la concentración de los gases. La alimentación con RFV se correlaciona de forma positiva con la concentración de gases, obteniendo valores de 0.33 para el metano y 0.61 para el dióxido de carbono. En contraste, para EV donde las correlaciones se pronunciaron negativas, de forma en la que la concentración de gases aumentaba conforme la alimentación de EV disminuía.

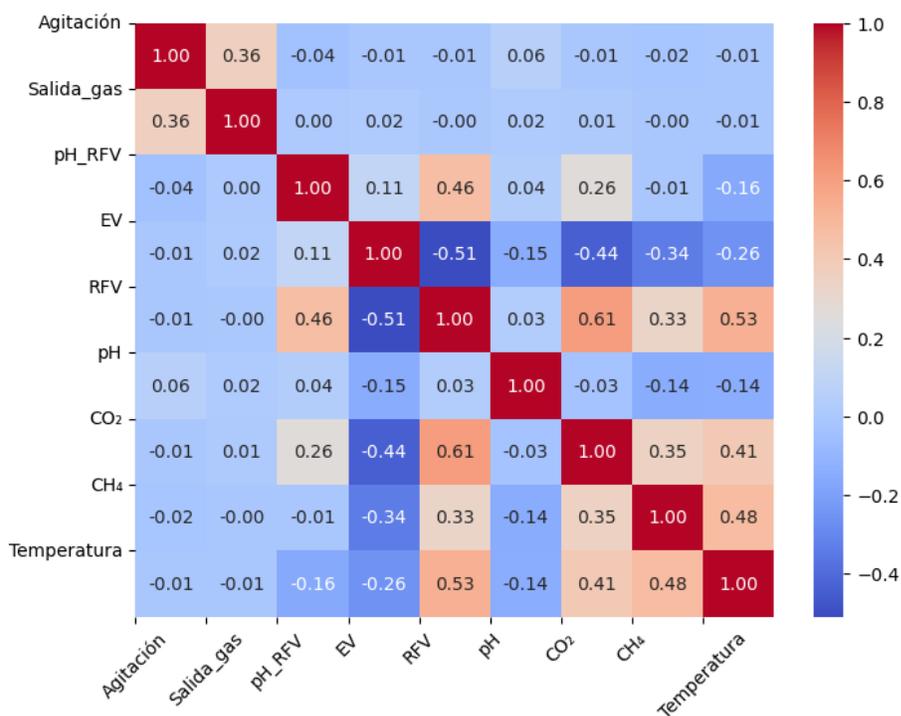


Figura 16. Correlación de Pearson.

En la Figura 17, el método de Spearman reveló que el pH tiene una correlación de 0.22 con el pH_RFV, de -0.18 con el EV y de -0.27 con la temperatura. La temperatura mostró una correlación positiva de 0.50 con el metano y de 0.32 con el dióxido de carbono. La alimentación con RFV se correlacionó positivamente con la concentración de dióxido de carbono de 0.70 y metano de 0.27. El EV presentó una correlación negativa con la concentración de metano de -0.28 y dióxido de carbono de -0.49, similar a lo observado con el método de Pearson. Las correlaciones del método

de Spearman, tanto positivas como negativas, son más pronunciadas en algunas variables, lo que sugiere posibles relaciones no lineales en los datos.

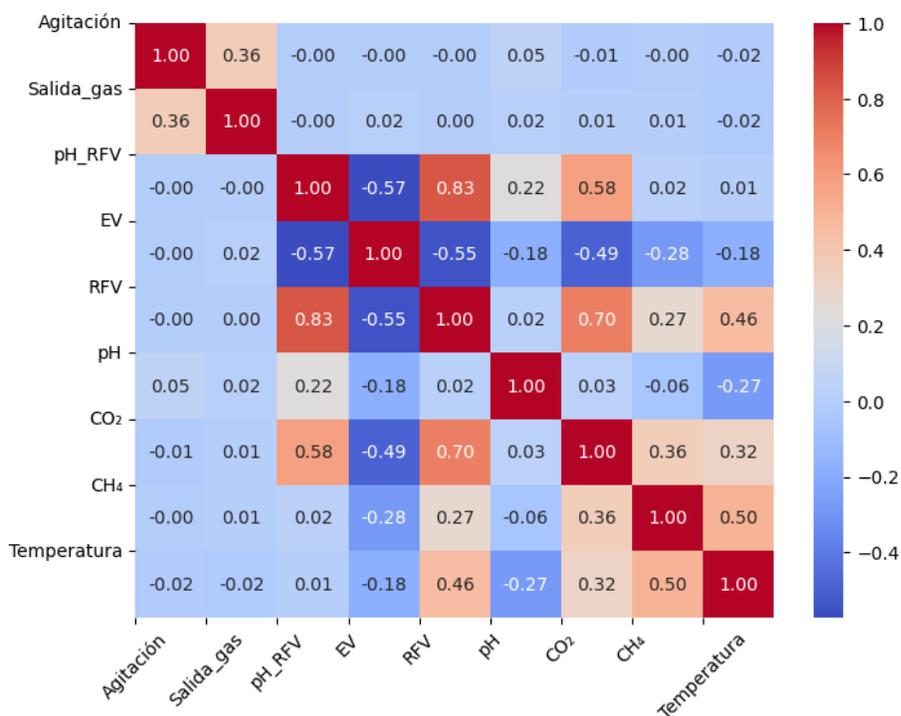


Figura 17. Correlación de Spearman.

La agitación y la extracción de biogás no presentaron correlación con las variables monitoreadas. La nula correlación que presentaron puede deberse a la naturaleza discreta del monitoreo de la agitación y extracción de biogás, que se registraron con valores de 1 y 2. En la Figura 9 y Figura 10, se observa la interacción entre la agitación con la concentración de gases. Por estos motivos, se decidió conservar la agitación y la extracción de biogás como variables de entrada. Finalmente, todas las variables fueron utilizadas como entradas para el *soft sensor*.

4.2.2 Optimización del *Soft Sensor*

El método de optimización de hiperparámetros de búsqueda en cuadrícula evaluó un total de 216 combinaciones con el propósito de encontrar la configuración óptima para el *soft sensor*. La mejor combinación de hiperparámetros es presentada en el Cuadro 8.

Cuadro 8. Hiperparámetros seleccionados por la búsqueda en cuadrícula.

Hiperparámetros	Selección
Función de activación	Sigmoide
Tamaño de lote	32
Épocas	20
Neuronas	64
Optimizador	SGD
Abandono recurrente	0.2

Durante este proceso se realizó una validación cruzada, donde los datos de entrenamiento se dividieron en 2 subconjuntos manteniendo la secuencia temporal de los datos, garantizando la evaluación del modelo en dos segmentos de los datos. Además, los datos de validación permitieron validar el rendimiento del modelo en un conjunto de datos separado, lo cual es fundamental para verificar la capacidad de generalización.

La búsqueda en cuadrícula es un método común y fácil de implementar. Sin embargo, al inicio de las evaluaciones se consideraron demasiados parámetros, lo que limitó su eficiencia debido al gran espacio de configuración de hiperparámetros, resultando en un alto costo computacional (Yang y Shami, 2020). La misma situación se presentó en un análisis exploratorio con optimización bayesiana. Al realizar la optimización de hiperparámetros en lotes, para evitar consumir todo el recurso computacional, se identificó una selección de parámetros que permite converger a un mínimo global.

4.2.3 Evaluación del *Soft Sensor*

La Figura 18 muestra el error cuadrado medio durante el periodo de entrenamiento y validación del modelo LSTM. Se observa que el error de la validación es menor que el del entrenamiento. Esto puede ser motivo que durante el entrenamiento se implementó un mecanismo de olvido recurrente para prevenir el sobreajuste del modelo, mientras que los datos de validación pueden ser más simples o menos complejos que los datos utilizados para el entrenamiento.

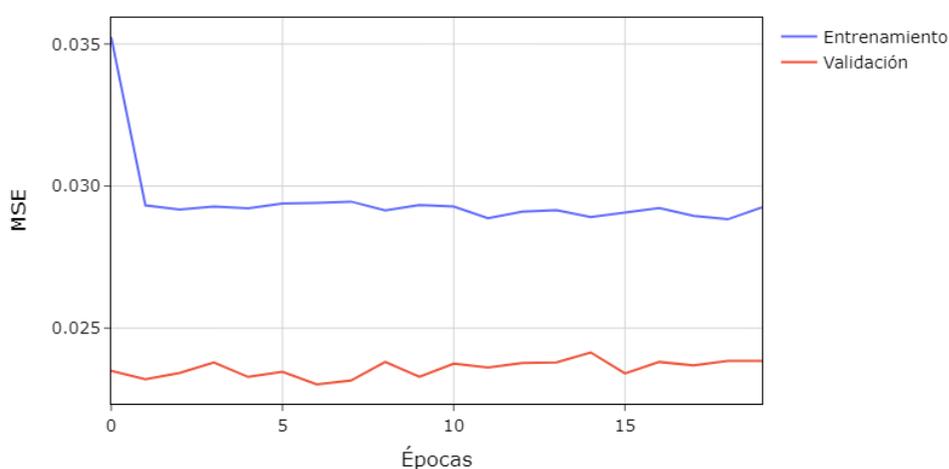


Figura 18. MSE en los datos de entrenamiento y validación.

Las predicciones obtenidas por el *soft sensor* se presentan en la Figura 19, sólo se muestra el periodo de prueba. El conjunto de prueba refleja la capacidad de generalización del *soft sensor* al realizar predicciones en nuevos casos que no ha visto anteriormente. También funciona como indicador para detectar problemas de sobreajuste (Géron, 2022). Las predicciones se mantienen estables a lo largo del tiempo, realizando leves ajustes acorde al comportamiento de los valores observados de pH. El MSE es de 0.0016, lo que indica que las predicciones son cercanas al valor real. El MAPE es de 0.4446% esto sugiere una buena precisión del *soft sensor* en términos porcentuales. Estos valores indican que las predicciones de pH generadas por el *soft sensor* tienen un promedio de error de sólo 0.0016 en la escala de pH 0-14.



Figura 19. Resultado de las predicciones del soft sensor.

El modelo LSTM se destaca como una herramienta potente para capturar la dependencia temporal en los bioprocesos (Park *et al.*, 2021). En este estudio, los resultados logrados a través de los indicadores de evaluación muestran rendimientos similares a otros trabajos relacionados en el desarrollo de *soft sensors* para predecir variables de interés de la DA. Jia *et al.*, (2022), midieron en línea el pH, conductividad eléctrica y el potencial de oxidación-reducción para predecir la alcalinidad, los AGV, la materia orgánica y la producción de metano. Su modelo de DL obtuvo resultados de MSE de 0.000961. McCormick y Villa, (2019), realizaron una evaluación comparativa de tres arquitecturas de redes neuronales artificiales para predecir la producción de biogás. Utilizaron como variables de entrada el flujo másico, el pH, la concentración de amonio y los AGV como entradas. En el análisis de la población completa, el modelo LSTM demostró un error cuadrático medio raíz del 1.7%. Los resultados obtenidos en las investigaciones demuestran la capacidad de los modelos de AI para realizar predicciones precisas. Mas allá de los resultados del modelo, es fundamental describir la metodología empleada en el desarrollo de estos modelos y su conexión con la DA. La descripción de la metodología es importante porque proporciona una base sólida que asegura la fiabilidad y validez de las predicciones, además, facilita que otras investigaciones puedan replicar análisis y estrategias. Esto contribuye al avance del conocimiento y al desarrollo de nuevas aplicaciones basadas en DA.

4.3 Limitaciones Relacionadas con los Sensores

Los sensores fueron seleccionados porque miden las condiciones de operación de la DA y sus productos de forma eficaz. Sin embargo, la DA representa un proceso complicado de monitorear debido a las condiciones adversas que genera el bioproceso en sí mismo. Esto puede derivar en datos no fiables e imprecisos que comprometen el rendimiento de los modelos de AI, lo que hace necesario sensores y sistemas de monitoreo robustos que capturen con precisión el proceso de la DA (Onu *et al.*, 2023).

Durante el desarrollo de esta investigación, se identificó la presencia de ruido en los sensores de concentración de gas, atribuida a la generación de gases corrosivos durante la DA, lo que afecta las lecturas de los sensores de gas (Bharathiraja *et al.*, 2018; Hanwei, n.d.). Además, el sensor de pH registró valores atípicos y ruido debido a la adherencia de partículas provenientes de los RFV en el medio. Estos efectos provocan que los sensores requieran mantenimiento y calibración periódica (Kazemi *et al.*, 2020). Una falla en la soldadura de la PCB ocasionó un falso contacto donde no se registraron datos en un corto periodo. El proceso de monitoreo también se vio afectado por la ocurrencia de fallas eléctricas y una recepción deficiente de la señal Wifi.

CONCLUSIONES

En general, esta investigación se conformó por un proceso con tres etapas principales: La fabricación del biodigestor, la implementación del sistema de instrumentación y monitoreo y el desarrollo del *soft sensor*. Cada etapa fue necesaria para continuar con la siguiente.

La fabricación del biodigestor garantizó la disponibilidad de un entorno adecuado para llevar a cabo la DA de la manera más controlada y eficiente posible. El sistema de monitoreo permitió registrar y analizar las variables del proceso, brindando datos precisos y confiables a través de la calibración y verificación periódica de los sensores. El desarrollo del *soft sensor* representó el paso más importante para transformar los datos del sistema de monitoreo en predicciones útiles y potencialmente aplicables en toma de decisiones, control y optimización de la digestión anaerobia.

Se desarrolló un *soft sensor* robusto y generalizado considerando la dependencia temporal de la digestión anaerobia. Con un MSE de 0.0016 en las predicciones del pH, el *soft sensor* ha demostrado su capacidad para manejar datos con alta dispersión y relaciones tanto lineales como no lineales.

El sistema de instrumentación y monitoreo logró capturar la dinámica del biodigestor de forma in situ, en línea y automática. A partir de un diseño adecuado y una correcta selección de dispositivos, este sistema demostró ser práctico y económico. Los datos, almacenados en una base de datos en la nube, permitieron ser consultados y procesados en todo momento.

El biodigestor, diseñado y fabricado con materiales de fácil adquisición para este estudio, permitió llevar a cabo el proceso de la DA y demostró flexibilidad y resistencia ante los dispositivos y conexiones que se le instalaron.

RECOMENDACIONES

Al realizar esta tesis, como parte de la experiencia surgieron las siguientes recomendaciones:

- Diseñar el sistema de agitación considerando las dimensiones del biodigestor, el tiempo de agitación y el tipo de agitador. Sustentar este diseño mediante el uso de dinámica computacional de fluidos.
- Garantizar la extracción y aprovechamiento del biogás y biofertilizantes derivados de la digestión anaerobia.
- Incorporar sensores con mayor resiliencia y especificidad. Particularmente en el monitoreo de gases, reemplazando los sensores electroquímicos por sensores de infrarrojo cercano.
- Explorar la versatilidad de los sistemas de instrumentación en la digestión anaerobia (e.g. añadiendo pantallas, fuentes de alimentación solares e internet de las cosas).
- Profundizar en la interpretación de los modelos de *Deep Learning* en las predicciones de la digestión anaerobia mediante el uso de métodos como el mecanismo de atención.
- Desarrollar aplicaciones web o móviles para el monitoreo en tiempo real de la digestión anaerobia, así como el uso en línea de *soft sensors*.
- Incorporar el *soft sensor* desarrollado en sistemas de control y optimización.

REFERENCIAS BIBLIOGRÁFICAS

- Abraham, E., Gupta, S., Jung, S., y McAfee, E. (2017). Bioreactor for Scale-Up: Process Control. In *Mesenchymal Stromal Cells: Translational Pathways to Clinical Adoption* (pp. 139–178). Elsevier. <https://doi.org/10.1016/B978-0-12-802826-1.00006-4>
- Agrawal, A., Chaudhari, P. K., y Ghosh, P. (2023). Anaerobic digestion of fruit and vegetable waste: a critical review of associated challenges. In *Environmental Science and Pollution Research* (Vol. 30, Issue 10, pp. 24987–25012). Springer Science and Business Media Deutschland GmbH. <https://doi.org/10.1007/s11356-022-21643-7>
- Aguilar, M. C., Wang, Y. D., Roskilly, T., Pathare, P. B., y Lamidi, R. O. (2017). Biogas from anaerobic co-digestion of food waste and primary sludge for cogeneration of power and heat. *Energy Procedia*, 142, 70–76. <https://doi.org/10.1016/j.egypro.2017.12.012>
- Ahmad, A., Yadav, A. K., Singh, A., y Singh, D. K. (2024). A comprehensive machine learning-coupled response surface methodology approach for predictive modeling and optimization of biogas potential in anaerobic Co-digestion of organic waste. *Biomass and Bioenergy*, 180. <https://doi.org/10.1016/j.biombioe.2023.106995>
- Al-Talib, A. A., Hoh Wen Yang, I., Idayu Mohd Tahir, N., Haslija Binti Abu Bakar, A., y Muhammad Afifi bin Zainal, N. (2024). Gas Detection for Biogas System Using Internet-of-Things(IoT). In *J:COM HorutoHall*.
- Andrade Cruz, I., Chuenchart, W., Long, F., Surendra, K. C., Renata Santos Andrade, L., Bilal, M., Liu, H., Tavares Figueiredo, R., Khanal, S. K., y Fernando Romanholo Ferreira, L. (2022). Application of machine learning in anaerobic digestion: Perspectives and challenges. *Bioresource Technology*, 345, 126433. <https://doi.org/10.1016/j.biortech.2021.126433>

- Andrade Cruz, I., Chuenchart, W., Long, F., Surendra, K., Santos Andrade, R., Bilal, M., Liu, H., Tavares Figueiredo, R., Kumar Khanal, S., y Fernando Romanholo Ferreira, L. (2021). *Application of machine learning in anaerobic digestion: Perspectives and 1 challenges 2 3*.
- Antolli, P. G., y Liu, Z. (2012). *Bioreactors : design, properties, and applications*. Nova Science Publishers.
- Ariunbaatar, J., Panico, A., Esposito, G., Pirozzi, F., y Lens, P. N. L. (2014). Pretreatment methods to enhance anaerobic digestion of organic solid waste. In *Applied Energy* (Vol. 123, pp. 143–156). Elsevier Ltd. <https://doi.org/10.1016/j.apenergy.2014.02.035>
- Ataee, S., Brochet, X., y Peña-Reyes, C. A. (2022). Bacteriophage Genetic Edition Using LSTM. *Frontiers in Bioinformatics*, 2. <https://doi.org/10.3389/fbinf.2022.932319>
- Atelge, M. R., Atabani, A. E., Banu, J. R., Krisa, D., Kaya, M., Eskicioglu, C., Kumar, G., Lee, C., Yildiz, Y., Unalan, S., Mohanasundaram, R., y Duman, F. (2020). A critical review of pretreatment technologies to enhance anaerobic digestion and energy recovery. *Fuel*, 270. <https://doi.org/10.1016/j.fuel.2020.117494>
- Azarmanesh, R., Zarghami Qaretapeh, M., Hasani Zonoozi, M., Ghiasinejad, H., y Zhang, Y. (2023). Anaerobic co-digestion of sewage sludge with other organic wastes: A comprehensive review focusing on selection criteria, operational conditions, and microbiology. In *Chemical Engineering Journal Advances* (Vol. 14). Elsevier B.V. <https://doi.org/10.1016/j.cej.2023.100453>
- Azevedo, A., Lapa, N., Moldão, M., y Duarte, E. (2023). Opportunities and Challenges in the Anaerobic co-Digestion of Municipal Sewage Sludge and Fruit and Vegetable Wastes: A review. *Energy Nexus*, 100202. <https://doi.org/10.1016/j.nexus.2023.100202>
- Bai, Y., Xiang, S., Cheng, F., y Zhao, J. (2023). A dynamic-inner LSTM prediction method for key alarm variables forecasting in chemical process. *Chinese*

Journal of Chemical Engineering, 55, 266–276.
<https://doi.org/10.1016/j.cjche.2022.08.024>

Bharathiraja, B., Sudharsana, T., Jayamuthunagai, J., Praveenkumar, R., Chozhavendhan, S., y Iyyappan, J. (2018). Biogas production – A review on composition, fuel properties, feed stock and principles of anaerobic digestion. In *Renewable and Sustainable Energy Reviews* (Vol. 90, pp. 570–582). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2018.03.093>

Biau, G., y Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197–227. <https://doi.org/10.1007/s11749-016-0481-7>

Bo Yang, P., Jing Chan, Y., Kazemi Yazdi, S., y Wei Lim, J. (2024). Optimisation and economic analysis of industrial-scale anaerobic co-digestion (ACoD) of palm oil mill effluent (POME) and decanter cake (DC) using machine learning models: A comparative study of Gradient Boosting Machines (GBM), K-nearest neighbours (KNN), and random forest (RF). *Journal of Water Process Engineering*, 58, 104752. <https://doi.org/10.1016/j.jwpe.2023.104752>

Bolton, W. (2021). Instrumentation and Control Systems. In *Instrumentation and Control Systems*. Elsevier. <https://doi.org/10.1016/b978-0-12-823471-6.00014-9>

Caetano, N. S., Mata, T. M., Martins, A. A., y Felgueiras, M. C. (2017). New Trends in Energy Production and Utilization. *Energy Procedia*, 107, 7–14. <https://doi.org/10.1016/j.egypro.2016.12.122>

Chandrashekar, G., y Sahin, F. (2014). A survey on feature selection methods. *Computers and Electrical Engineering*, 40(1), 16–28. <https://doi.org/10.1016/j.compeleceng.2013.11.024>

Chen, Y., Rößler, B., Zielonka, S., Lemmer, A., Wonneberger, A. M., y Jungbluth, T. (2014). The pressure effects on two-phase anaerobic digestion. *Applied Energy*, 116, 409–415. <https://doi.org/10.1016/j.apenergy.2013.11.012>

- Choudhury, A., Lepine, C., Witarsa, F., y Good, C. (2022). Anaerobic digestion challenges and resource recovery opportunities from land-based aquaculture waste and seafood processing byproducts: A review. In *Bioresource Technology* (Vol. 354). Elsevier Ltd. <https://doi.org/10.1016/j.biortech.2022.127144>
- Cruz, I. A., Andrade, L. R. S., Bharagava, R. N., Nadda, A. K., Bilal, M., Figueiredo, R. T., y Ferreira, L. F. R. (2021). An overview of process monitoring for anaerobic digestion. *Biosystems Engineering*, 207, 106–119. <https://doi.org/10.1016/j.biosystemseng.2021.04.008>
- Dahunsi, S. O., Oranusi, S., y Efeovbokhan, V. E. (2017). Cleaner energy for cleaner production: Modeling and optimization of biogas generation from Carica papayas (Pawpaw) fruit peels. *Journal of Cleaner Production*, 156, 19–29. <https://doi.org/10.1016/j.jclepro.2017.04.042>
- David, B., Federico, B., Cristina, C., Marco, G., Federico, M., y Paolo, P. (2019). Biohythane Production From Food Wastes. In *Biomass, Biofuels, Biochemicals: Biohydrogen, Second Edition* (pp. 347–368). Elsevier. <https://doi.org/10.1016/B978-0-444-64203-5.00013-7>
- De Clercq, D., Jalota, D., Shang, R., Ni, K., Zhang, Z., Khan, A., Wen, Z., Caicedo, L., y Yuan, K. (2019). Machine learning powered software for accurate prediction of biogas production: A case study on industrial-scale Chinese production data. *Journal of Cleaner Production*, 218, 390–399. <https://doi.org/10.1016/j.jclepro.2019.01.031>
- Drosg, B. (2013). *Process monitoring in biogas plants Process monitoring in biogas plants Process monitoring in biogas plants*.
- Géron, A. (2022). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media, Inc.
- Gómez-Camacho, C. E., Pirone, R., y Ruggeri, B. (2021). Is the Anaerobic Digestion (AD) sustainable from the energy point of view? *Energy Conversion and Management*, 231. <https://doi.org/10.1016/j.enconman.2021.113857>

- Gu, Y. H., Jin, D., Yin, H., Zheng, R., Piao, X., y Yoo, S. J. (2022). Forecasting Agricultural Commodity Prices Using Dual Input Attention LSTM. *Agriculture (Switzerland)*, 12(2). <https://doi.org/10.3390/agriculture12020256>
- Gupta, R., Zhang, L., Hou, J., Zhang, Z., Liu, H., You, S., Sik Ok, Y., y Li, W. (2023). Review of Explainable Machine Learning for Anaerobic Digestion 1. *Bioresource Technology*, 369.
- Hamilton, D. W. (2010). *Anaerobic Digestion of Animal Manures: Types of Digesters*. <http://osufacts.okstate.edu>
- Hansen, C. L., y Cheong, D. Y. (2019). Agricultural Waste Management in Food Processing. In *Handbook of Farm, Dairy and Food Machinery Engineering* (pp. 673–716). Elsevier. <https://doi.org/10.1016/B978-0-12-814803-7.00026-9>
- Hanwei, E. Co. LT. (n.d.). *Technical Data MQ-135 Gas Sensor*.
- Hasan, M. W. (2023). Building an IoT temperature and humidity forecasting model based on long short-term memory (LSTM) with improved whale optimization algorithm. *Memories - Materials, Devices, Circuits and Systems*, 6, 100086. <https://doi.org/10.1016/j.memori.2023.100086>
- He, F., Zhou, J., Feng, Z. kai, Liu, G., y Yang, Y. (2019). A hybrid short-term load forecasting model based on variational mode decomposition and long short-term memory networks considering relevant factors with Bayesian optimization algorithm. *Applied Energy*, 237, 103–116. <https://doi.org/10.1016/j.apenergy.2019.01.055>
- Hochreiter, Sepp., y Schmidhuber, Jurgen. (1997). LONG SHORT-TERM MEMORY. *Neural Computation*, 9(8), 1735–1780.
- Jaibiba, P., Naga Vignesh, S., y Hariharan, S. (2020). Working principle of typical bioreactors. In *Bioreactors* (pp. 145–173). Elsevier. <https://doi.org/10.1016/B978-0-12-821264-6.00010-3>

- Jakhar, D., y Kaur, I. (2020). Artificial intelligence, machine learning and deep learning: definitions and differences. *Clinical and Experimental Dermatology*, 45(1), 131–132. <https://doi.org/10.1111/ced.14029>
- Jia, R., Song, Y. C., Piao, D. M., Kim, K., Lee, C. Y., y Park, J. (2022). Exploration of deep learning models for real-time monitoring of state and performance of anaerobic digestion with online sensors. *Bioresource Technology*, 363. <https://doi.org/10.1016/j.biortech.2022.127908>
- Jiang, Y., Yin, S., Dong, J., y Kaynak, O. (2021). A Review on Soft Sensors for Monitoring, Control, and Optimization of Industrial Processes. In *IEEE Sensors Journal* (Vol. 21, Issue 11, pp. 12868–12881). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/JSEN.2020.3033153>
- Kabeyi, M. J. B., y Olanrewaju, O. A. (2022). Technologies for biogas to electricity conversion. *Energy Reports*, 8, 774–786. <https://doi.org/10.1016/j.egyr.2022.11.007>
- Kazemi, P., Bengoa, C., Steyer, J. P., y Giralt, J. (2021). Data-driven techniques for fault detection in anaerobic digestion process. *Process Safety and Environmental Protection*, 146, 905–915. <https://doi.org/10.1016/j.psep.2020.12.016>
- Kazemi, P., Steyer, J. P., Bengoa, C., Font, J., y Giralt, J. (2020). Robust data-driven soft sensors for online monitoring of volatile fatty acids in anaerobic digestion processes. *Processes*, 8(1). <https://doi.org/10.3390/pr8010067>
- Khaki, S., Wang, L., y Archontoulis, S. V. (2020). A CNN-RNN Framework for Crop Yield Prediction. *Frontiers in Plant Science*, 10. <https://doi.org/10.3389/fpls.2019.01750>
- Khanal, S. K., Tarafdar, A., y You, S. (2023). Artificial intelligence and machine learning for smart bioprocesses. *Bioresource Technology*, 375, 128826. <https://doi.org/10.1016/j.biortech.2023.128826>

- Khanh Nguyen, V., Kumar Chaudhary, D., Hari Dahal, R., Hoang Trinh, N., Kim, J., Chang, S. W., Hong, Y., Duc La, D., Nguyen, X. C., Hao Ngo, H., Chung, W. J., y Nguyen, D. D. (2021). Review on pretreatment techniques to improve anaerobic digestion of sewage sludge. *Fuel*, 285. <https://doi.org/10.1016/j.fuel.2020.119105>
- Komilis, D., Barrena, R., Grando, R. L., Vogiatzi, V., Sánchez, A., y Font, X. (2017). A state of the art literature review on anaerobic digestion of food waste: influential operating parameters on methane yield. In *Reviews in Environmental Science and Biotechnology* (Vol. 16, Issue 2, pp. 347–360). Springer Netherlands. <https://doi.org/10.1007/s11157-017-9428-z>
- Kramer, O. (2013). Dimensionality Reduction with Unsupervised Nearest Neighbors. In *INTELLIGENT SYSTEMS REFERENCE LIBRARY* (Vol. 51). Springer Berlin Heidelberg. <https://doi.org/10.1007/978-3-642-38652-7>
- Kunatsa, T., y Xia, X. (2022). A review on anaerobic digestion with focus on the role of biomass co-digestion, modelling and optimisation on biogas production and enhancement. In *Bioresource Technology* (Vol. 344). Elsevier Ltd. <https://doi.org/10.1016/j.biortech.2021.126311>
- Lecun, Y., Bengio, Y., y Hinton, G. (2015). Deep learning. In *Nature* (Vol. 521, Issue 7553, pp. 436–444). Nature Publishing Group. <https://doi.org/10.1038/nature14539>
- Levenspiel, O. (1998). *Chemical reaction engineering* (3rd ed.). John Wiley y Sons.
- Li, H., Mehmood, D., Thorin, E., y Yu, Z. (2017). Biomethane Production Via Anaerobic Digestion and Biomass Gasification. *Energy Procedia*, 105, 1172–1177. <https://doi.org/10.1016/j.egypro.2017.03.490>
- Li, J., Zhang, L., Li, C., Tian, H., Ning, J., Zhang, J., Tong, Y. W., y Wang, X. (2022). Data-Driven Based In-Depth Interpretation and Inverse Design of Anaerobic Digestion for CH₄-Rich Biogas Production. *ACS ES and T Engineering*, 2(4), 642–652. <https://doi.org/10.1021/acsestengg.1c00316>

- Li, Y., Achinas, S., Zhao, J., Geurkink, B., Krooneman, J., y Willem Euverink, G. J. (2020). Co-digestion of cow and sheep manure: Performance evaluation and relative microbial activity. *Renewable Energy*, 153, 553–563. <https://doi.org/10.1016/j.renene.2020.02.041>
- Li, Y., Park, S. Y., y Zhu, J. (2011). Solid-state anaerobic digestion for methane production from organic waste. In *Renewable and Sustainable Energy Reviews* (Vol. 15, Issue 1, pp. 821–826). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2010.07.042>
- Lim, H. C., y Shin, H. S. (2013). *Fed-batch cultures : principles and applications of semi-batch bioreactors*. Cambridge University Press.
- Lim, S. J., Son, M., Ki, S. J., Suh, S. I., y Chung, J. (2023). Opportunities and challenges of machine learning in bioprocesses: Categorization from different perspectives and future direction. *Bioresource Technology*, 370. <https://doi.org/10.1016/j.biortech.2022.128518>
- Lin, J., Zuo, J., Gan, L., Li, P., Liu, F., Wang, K., Chen, L., y Gan, H. (2011). Effects of mixture ratio on anaerobic co-digestion with fruit and vegetable waste and food waste of China. *Journal of Environmental Sciences*, 23(8), 1403–1408. [https://doi.org/10.1016/S1001-0742\(10\)60572-4](https://doi.org/10.1016/S1001-0742(10)60572-4)
- Liu, X., Khalid, H., Amin, F. R., Ma, X., Li, X., Chen, C., y Liu, G. (2018). Effects of hydraulic retention time on anaerobic digestion performance of food waste to produce methane as a biofuel. *Environmental Technology and Innovation*, 11, 348–357. <https://doi.org/10.1016/j.eti.2018.06.004>
- Liu, Y., Tian, W., Xie, J., Huang, W., y Xin, K. (2023). LSTM-Based Model-Predictive Control with Rationality Verification for Bioreactors in Wastewater Treatment. *Water (Switzerland)*, 15(9). <https://doi.org/10.3390/w15091779>
- Long, F., Wang, L., Cai, W., Lesnik, K., y Liu, H. (2021). Predicting the performance of anaerobic digestion using machine learning algorithms and genomic data. *Water Research*, 199. <https://doi.org/10.1016/j.watres.2021.117182>

- López-Sánchez, A., Silva-Gálvez, A. L., González-López, M. E., Díaz-Vázquez, D., Orozco-Nunnally, D. A., Novoa-Leiva, I., González-Valdez, J., Casillas-García, L. F., y Gradilla-Hernández, M. S. (2023). Valorization of livestock waste through combined anaerobic digestion and microalgae-based treatment in México: A techno-economic analysis for distributed biogas generation, animal feed production, and carbon credits trading. *Environmental Technology and Innovation*, 32. <https://doi.org/10.1016/j.eti.2023.103321>
- Matheri, A. N., Ndiweni, S. N., Belaid, M., Muzenda, E., y Hubert, R. (2017). Optimising biogas production from anaerobic co-digestion of chicken manure and organic fraction of municipal solid waste. In *Renewable and Sustainable Energy Reviews* (Vol. 80, pp. 756–764). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2017.05.068>
- McCormick, M., y Villa, A. E. P. (2019). LSTM and 1-D Convolutional Neural Networks for Predictive Monitoring of the Anaerobic Digestion Process. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11731 LNCS, 725–736. https://doi.org/10.1007/978-3-030-30493-5_65
- Meegoda, J. N., Li, B., Patel, K., y Wang, L. B. (2018). A review of the processes, parameters, and optimization of anaerobic digestion. In *International Journal of Environmental Research and Public Health* (Vol. 15, Issue 10). MDPI AG. <https://doi.org/10.3390/ijerph15102224>
- Mendiola-Rodriguez, T. A., y Ricardez-Sandoval, L. A. (2022). Robust control for anaerobic digestion systems of Tequila vinasses under uncertainty: A Deep Deterministic Policy Gradient Algorithm. *Digital Chemical Engineering*, 3, 100023. <https://doi.org/10.1016/j.dche.2022.100023>
- Michelucci, U. (2022). *An Introduction to Autoencoders*. <http://arxiv.org/abs/2201.03898>

- Mir, M. A., Hussain, A., y Verma, C. (2016). Design considerations and operational performance of anaerobic digester: A review. *Cogent Engineering*, 3(1). <https://doi.org/10.1080/23311916.2016.1181696>
- Naga Vignesh, S. (2020). Working principle of typical bioreactors. In *Bioreactors: Sustainable Design and Industrial Applications in Mitigation of GHG Emissions* (pp. 145–173). Elsevier. <https://doi.org/10.1016/B978-0-12-821264-6.00010-3>
- Nguyen, D., Gadhamshetty, V., Nitayavardhana, S., y Khanal, S. K. (2015). Automatic process control in anaerobic digestion technology: A critical review. In *Bioresource Technology* (Vol. 193, pp. 513–522). Elsevier Ltd. <https://doi.org/10.1016/j.biortech.2015.06.080>
- Nizami, A. S., Saville, B. A., y MacLean, H. L. (2013). Anaerobic digesters: perspectives and challenges. In *Bioenergy production by anaerobic digestion* (pp. 139–151).
- NMX-AA-16-1984. (1992). *NORMA MEXICANA NMX-AA-16-1984. PROTECCIÓN AL AMBIENTE -CONTAMINACIÓN DEL SUELO - RESIDUOS SÓLIDOS MUNICIPALES - DETERMINACIÓN DE HUMEDAD.*
- NMX-AA-25-1984. (1992). *NORMA MEXICANA NMX-AA-25-1984. PROTECCIÓN AL AMBIENTE-CONTAMINACIÓN DEL SUELO-RESIDUOS SÓLIDOS-DETERMINACIÓN DEL pH-MÉTODO POTENCIOMÉTRICO.*
- Onu, P., Mbohwa, C., y Pradhan, A. (2023). *Artificial intelligence-based IoT-enabled biogas production.* 1–6. <https://doi.org/10.1109/iccad57653.2023.10152349>
- Ounsaneha, W., Rattanapan, C., Suksaroj, T. T., Kantachote, D., Klaweck, W., y Rakkamon, T. (2021). Biogas production by co-digestion of municipal wastewater and food waste: Performance in semi-continuous and continuous operation. *Water Environment Research*, 93(2), 306–315. <https://doi.org/10.1002/wer.1413>

- Pandian, I., Begum, S., y Kumaravel, S. P. (2021). An integrated IoT and fuzzy logic controller system for biogas digester to predict methane generation. *Environment, Development and Sustainability*. <https://doi.org/10.1007/s10668-021-01943-7>
- Panigrahi, S., y Dubey, B. K. (2019). A critical review on operating parameters and strategies to improve the biogas yield from anaerobic digestion of organic fraction of municipal solid waste. In *Renewable Energy* (Vol. 143, pp. 779–797). Elsevier Ltd. <https://doi.org/10.1016/j.renene.2019.05.040>
- Paritosh, K., Kushwaha, S. K., Yadav, M., Pareek, N., Chawade, A., y Vivekanand, V. (2017). Food Waste to Energy: An Overview of Sustainable Approaches for Food Waste Management and Nutrient Recycling. In *BioMed Research International* (Vol. 2017). Hindawi Limited. <https://doi.org/10.1155/2017/2370927>
- Park, J. G., Jun, H. B., y Heo, T. Y. (2021). Retraining prior state performances of anaerobic digestion improves prediction accuracy of methane yield in various machine learning models. *Applied Energy*, 298(May), 117250. <https://doi.org/10.1016/j.apenergy.2021.117250>
- Pathak, H., Jain, N., Bhatia, A., Mohanty, S., y Gupta, N. (2009). Global warming mitigation potential of biogas plants in India. *Environmental Monitoring and Assessment*, 157(1–4), 407–418. <https://doi.org/10.1007/s10661-008-0545-6>
- Pavi, S., Kramer, L. E., Gomes, L. P., y Miranda, L. A. S. (2017). Biogas production from co-digestion of organic fraction of municipal solid waste and fruit and vegetable waste. In *Bioresource Technology* (Vol. 228, pp. 362–367). Elsevier Ltd. <https://doi.org/10.1016/j.biortech.2017.01.003>
- Pellera, F. M., y Gidakos, E. (2017). Anaerobic digestion of solid agroindustrial waste in semi-continuous mode: Evaluation of mono-digestion and co-digestion systems. *Waste Management*, 68, 103–119. <https://doi.org/10.1016/j.wasman.2017.06.026>

- Perera, Y. S., Ratnaweera, D. A. A. C., Dasanayaka, C. H., y Abeykoon, C. (2023). The role of artificial intelligence-driven soft sensors in advanced sustainable process industries: A critical review. In *Engineering Applications of Artificial Intelligence* (Vol. 121). Elsevier Ltd. <https://doi.org/10.1016/j.engappai.2023.105988>
- Reif, R., Omil, F., y Lema, J. M. (2013). Removal of pharmaceuticals by membrane bioreactor (MBR) technology. In *Comprehensive Analytical Chemistry* (Vol. 62, pp. 287–317). Elsevier B.V. <https://doi.org/10.1016/B978-0-444-62657-8.00009-4>
- Ren, L., Wang, T., Laili, Y., y Zhang, L. (2022). A Data-Driven Self-Supervised LSTM-DeepFM Model for Industrial Soft Sensor. *IEEE Transactions on Industrial Informatics*, 18(9), 5859–5869. <https://doi.org/10.1109/TII.2021.3131471>
- Rösner, L. S., Walter, F., Ude, C., John, G. T., y Beutel, S. (2022). Sensors and Techniques for On-Line Determination of Cell Viability in Bioprocess Monitoring. In *Bioengineering* (Vol. 9, Issue 12). MDPI. <https://doi.org/10.3390/bioengineering9120762>
- Rowan, M., Umenweke, G. C., Epelle, E. I., Afolabi, I. C., Okoye, P. U., Gunes, B., y Okolie, J. A. (2022). Anaerobic co-digestion of food waste and agricultural residues: An overview of feedstock properties and the impact of biochar addition. In *Digital Chemical Engineering* (Vol. 4). Elsevier Ltd. <https://doi.org/10.1016/j.dche.2022.100046>
- Rutland, H., You, J., Liu, H., Bull, L., y Reynolds, D. (2023). A Systematic Review of Machine-Learning Solutions in Anaerobic Digestion. In *Bioengineering* (Vol. 10, Issue 12). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/bioengineering10121410>
- Salehi, H., y Burgueño, R. (2018). *Emerging artificial intelligence methods in structural engineering*. <https://www.sciencedirect.com/science/article/pii/S0141029617335526>

- Sarker, S., Lamb, J. J., Hjelme, D. R., y Lien, K. M. (2019). A review of the role of critical parameters in the design and operation of biogas production plants. In *Applied Sciences (Switzerland)* (Vol. 9, Issue 9). MDPI AG. <https://doi.org/10.3390/app9091915>
- Seo, K. W., Seo, J., Kim, K., Ji Lim, S., y Chung, J. (2021). Prediction of biogas production rate from dry anaerobic digestion of food waste: Process-based approach vs. recurrent neural network black-box model. *Bioresource Technology*, 341. <https://doi.org/10.1016/j.biortech.2021.125829>
- Shalev-Shwartz, S., y Ben-David, S. (2014). *Understanding Machine Learning: From Theory to Algorithms*. Cambridge University Press. <http://www.cs.huji.ac.il/~shais/UnderstandingMachineLearning>
- Shen, F., Yuan, H., Pang, Y., Chen, S., Zhu, B., Zou, D., Liu, Y., Ma, J., Yu, L., y Li, X. (2013). Performances of anaerobic co-digestion of fruit y vegetable waste (FVW) and food waste (FW): Single-phase vs. two-phase. *Bioresource Technology*, 144, 80–85. <https://doi.org/10.1016/j.biortech.2013.06.099>
- Shinde, P. P., y Shah, S. (2018). A Review of Machine Learning and Deep Learning Applications. *2018 Fourth International Conference on Computing Communication Control and Automation (ICCUBEA)*, 1–6. <https://doi.org/10.1109/ICCUBEA.2018.8697857>
- Staudemeyer, R. C., y Morris, E. R. (2019). *Understanding LSTM -- a tutorial into Long Short-Term Memory Recurrent Neural Networks*. <http://arxiv.org/abs/1909.09586>
- Sun, Q., y Ge, Z. (2021). A Survey on Deep Learning for Data-Driven Soft Sensors. *IEEE Transactions on Industrial Informatics*, 17(9), 5853–5866. <https://doi.org/10.1109/TII.2021.3053128>
- Talevi, M., Pattanayak, S. K., Das, I., Lewis, J. J., y Singha, A. K. (2022). Speaking from experience: Preferences for cooking with biogas in rural India. *Energy Economics*, 107. <https://doi.org/10.1016/j.eneco.2021.105796>

- Usack, J. G., Spirito, C. M., y Angenent, L. T. (2012). Continuously-stirred anaerobic digester to convert organic wastes into biogas: System setup and basic operation. *Journal of Visualized Experiments*, 65. <https://doi.org/10.3791/3978>
- Utami, A. R. I., Ryantara, R. A., Sumaryatie, E. D., y Chandra, I. (2021). Analysis of the effect of internal gas pressure of an anaerobic digester on biogas productivity of a mixture of cow dung and tofu liquid waste. *AIP Conference Proceedings*, 2320. <https://doi.org/10.1063/5.0037446>
- Van, D. P., Fujiwara, T., Tho, B. L., Toan, P. P. S., y Minh, G. H. (2020). A review of anaerobic digestion systems for biodegradable waste: Configurations, operating parameters, and current trends. In *Environmental Engineering Research* (Vol. 25, Issue 1, pp. 1–17). Korean Society of Environmental Engineers. <https://doi.org/10.4491/eer.2018.334>
- Venkatasubramanian, V. (2019). The promise of artificial intelligence in chemical engineering: Is it here, finally? *AIChE Journal*, 65(2), 466–478. <https://doi.org/10.1002/aic.16489>
- Waewsak, C., Nopharatana, A., y Chaiprasert, P. (2010). Neural-fuzzy control system application for monitoring process response and control of anaerobic hybrid reactor in wastewater treatment and biogas production. *Journal of Environmental Sciences*, 22(12), 1883–1890. [https://doi.org/10.1016/S1001-0742\(09\)60334-X](https://doi.org/10.1016/S1001-0742(09)60334-X)
- Walid, F., El Fkihi, S., Benbrahim, H., y Tagemouati, H. (2021). Modeling and optimization of anaerobic digestion: A review. *E3S Web of Conferences*, 229. <https://doi.org/10.1051/e3sconf/202122901022>
- Wang, S.-J., y Zhong, J.-J. (2007). *Chapter 6. Bioreactor Engineering*.
- Wang, X., Rashid, I., Zhao, Z., Oladele, M., Xiang, W., Huang, Y., Wazer, E., McCutcheon, J., Bollas, G., Contreras, J., y Li, B. (2023). Machine Learning Algorithm Integrated with Real-Time In Situ Sensors and Physiochemical Principle-Driven Soft Sensors toward an Anaerobic Digestion-Data Fusion

- Framework. *ACS ES and T Water*.
<https://doi.org/10.1021/acsestwater.3c00236>
- Wang, Y., Yan, P., y Gai, M. (2021). Dynamic Soft Sensor for Anaerobic Digestion of Kitchen Waste Based on SGSTGAT. *IEEE Sensors Journal*, 21(17), 19198–19208. <https://doi.org/10.1109/JSEN.2021.3090524>
- Webster, J., y Eren, H. (Eds.). (2018). *Measurement, Instrumentation, and Sensors Handbook: Two-Volume Set* (2nd ed.). CRC press.
- Woschank, M., Rauch, E., y Zsifkovits, H. (2020). A review of further directions for artificial intelligence, machine learning, and deep learning in smart logistics. *Sustainability (Switzerland)*, 12(9). <https://doi.org/10.3390/su12093760>
- Wu, D., Li, L., Peng, Y., Yang, P., Peng, X., Sun, Y., y Wang, X. (2021). State indicators of anaerobic digestion: A critical review on process monitoring and diagnosis. In *Renewable and Sustainable Energy Reviews* (Vol. 148). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2021.111260>
- Wu, D., Li, L., Zhao, X., Peng, Y., Yang, P., y Peng, X. (2019). Anaerobic digestion: A review on process monitoring. In *Renewable and Sustainable Energy Reviews* (Vol. 103, pp. 1–12). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2018.12.039>
- Wu, Y., y Song, K. (2021). Anaerobic co-digestion of waste activated sludge and fish waste: Methane production performance and mechanism analysis. *Journal of Cleaner Production*, 279. <https://doi.org/10.1016/j.jclepro.2020.123678>
- Yan, P., Gai, M., Wang, Y., y Gao, X. (2021). Review of soft sensors in anaerobic digestion process. *Processes*, 9(8). <https://doi.org/10.3390/pr9081434>
- Yang, L., y Shami, A. (2020). *On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice*. <https://doi.org/10.1016/j.neucom.2020.07.061>

- Yilmaz, D., y Büyüktaktın, I. E. (2023). Learning Optimal Solutions via an LSTM-Optimization Framework. *Operations Research Forum*, 4(2). <https://doi.org/10.1007/s43069-023-00224-5>
- Zhang, C., Su, H., Wang, Z., Tan, T., y Qin, P. (2015). Biogas by Semi-Continuous Anaerobic Digestion of Food Waste. *Applied Biochemistry and Biotechnology*, 175(8), 3901–3914. <https://doi.org/10.1007/s12010-015-1559-5>
- Zhang, C., Ye, H., Liu, F., He, Y., Kong, W., y Sheng, K. (2016). Determination and visualization of pH values in anaerobic digestion of water hyacinth and rice straw mixtures using hyperspectral imaging with wavelet transform denoising and variable selection. *Sensors (Switzerland)*, 16(2). <https://doi.org/10.3390/s16020244>
- Zhong, J. J. (2010). Recent advances in bioreactor engineering. *Korean Journal of Chemical Engineering*, 27(4), 1035–1041. <https://doi.org/10.1007/s11814-010-0277-5>

ANEXOS



Figura A 1. Biodigestor semi-continuo.



Figura A 2. Construcción de la base del biodigestor.



Figura A 3. Componentes del sistema de agitación.



Figura A 4. Residuos de frutas y verduras utilizadas como sustrato.



Figura A 5. Estiércol de vaca utilizado como inóculo y co-sustrato.

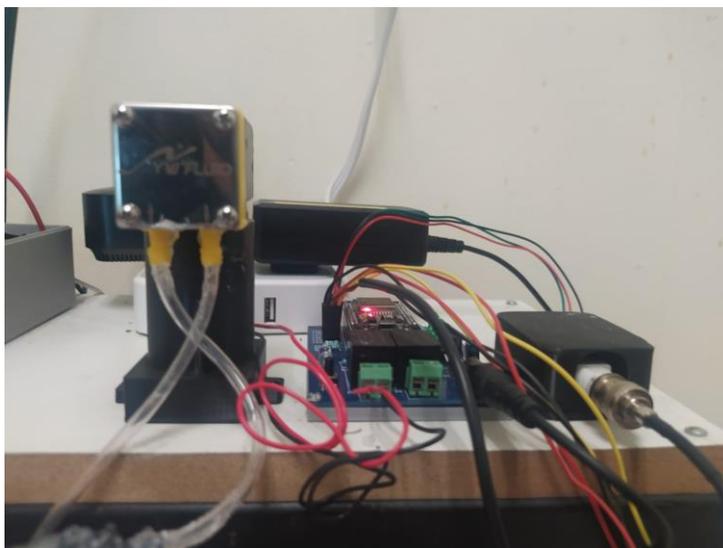


Figura A 6. Bomba de vacío y PCB en la base de la instrumentación.

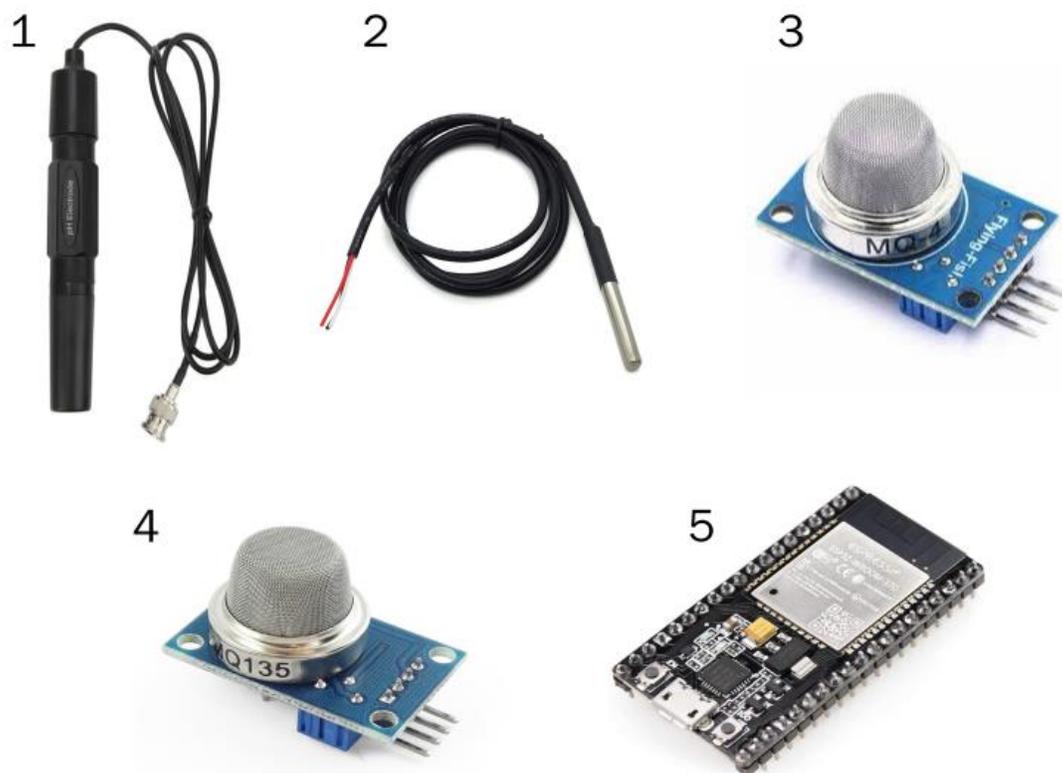


Figura A 7. Instrumentos utilizados. 1) Electrodo pH-201H. 2) DS18B20. 3) MQ-4. 4) MQ-135. 5) Esp32. Imágenes tomadas de la red.

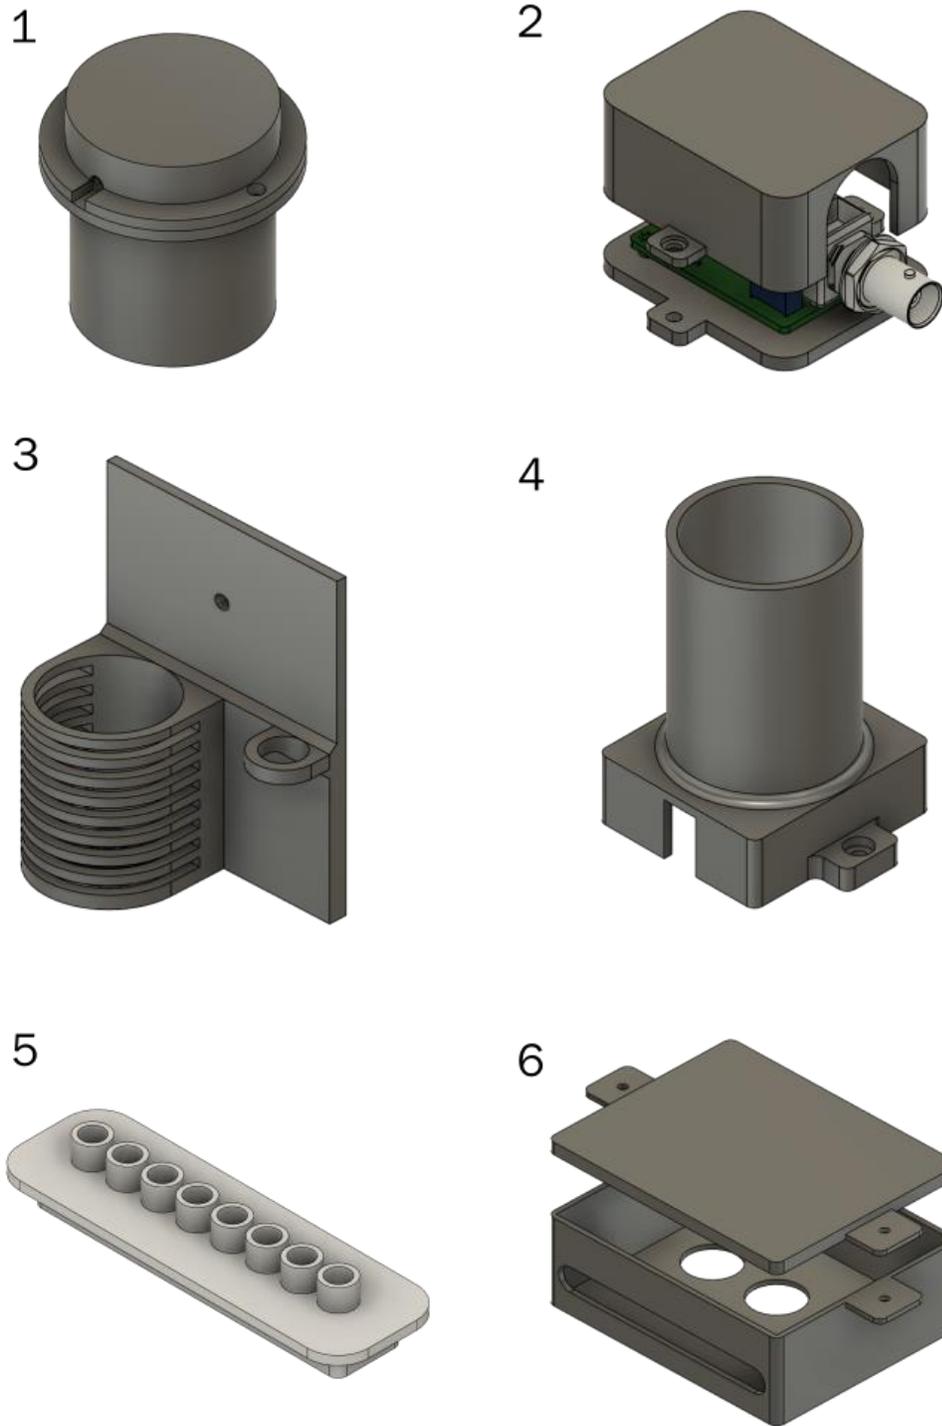


Figura A 8. Piezas impresas en 3D. 1) Conexión del electrodo de pH. 2) Caja del sensor de pH. 3) Soporte del electrodo de pH y del sensor DS18B20. 4) Soporte de la bomba de vacío. 5) Conexión para cables de sensores. 6) Soporte de los sensores MQ.

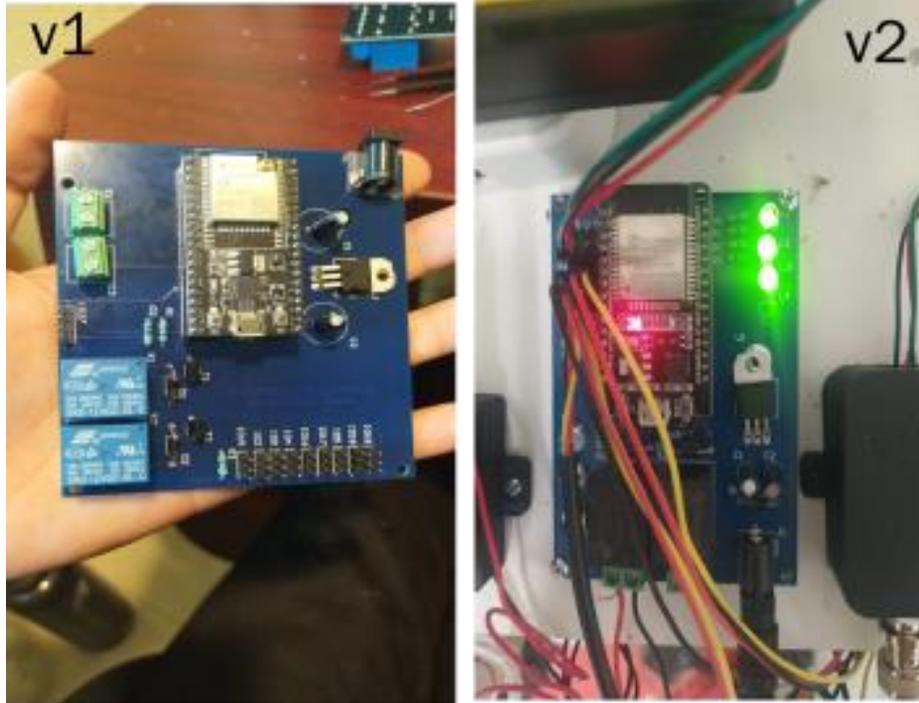


Figura A 9. Versión 1 y versión 2 de las PCB.

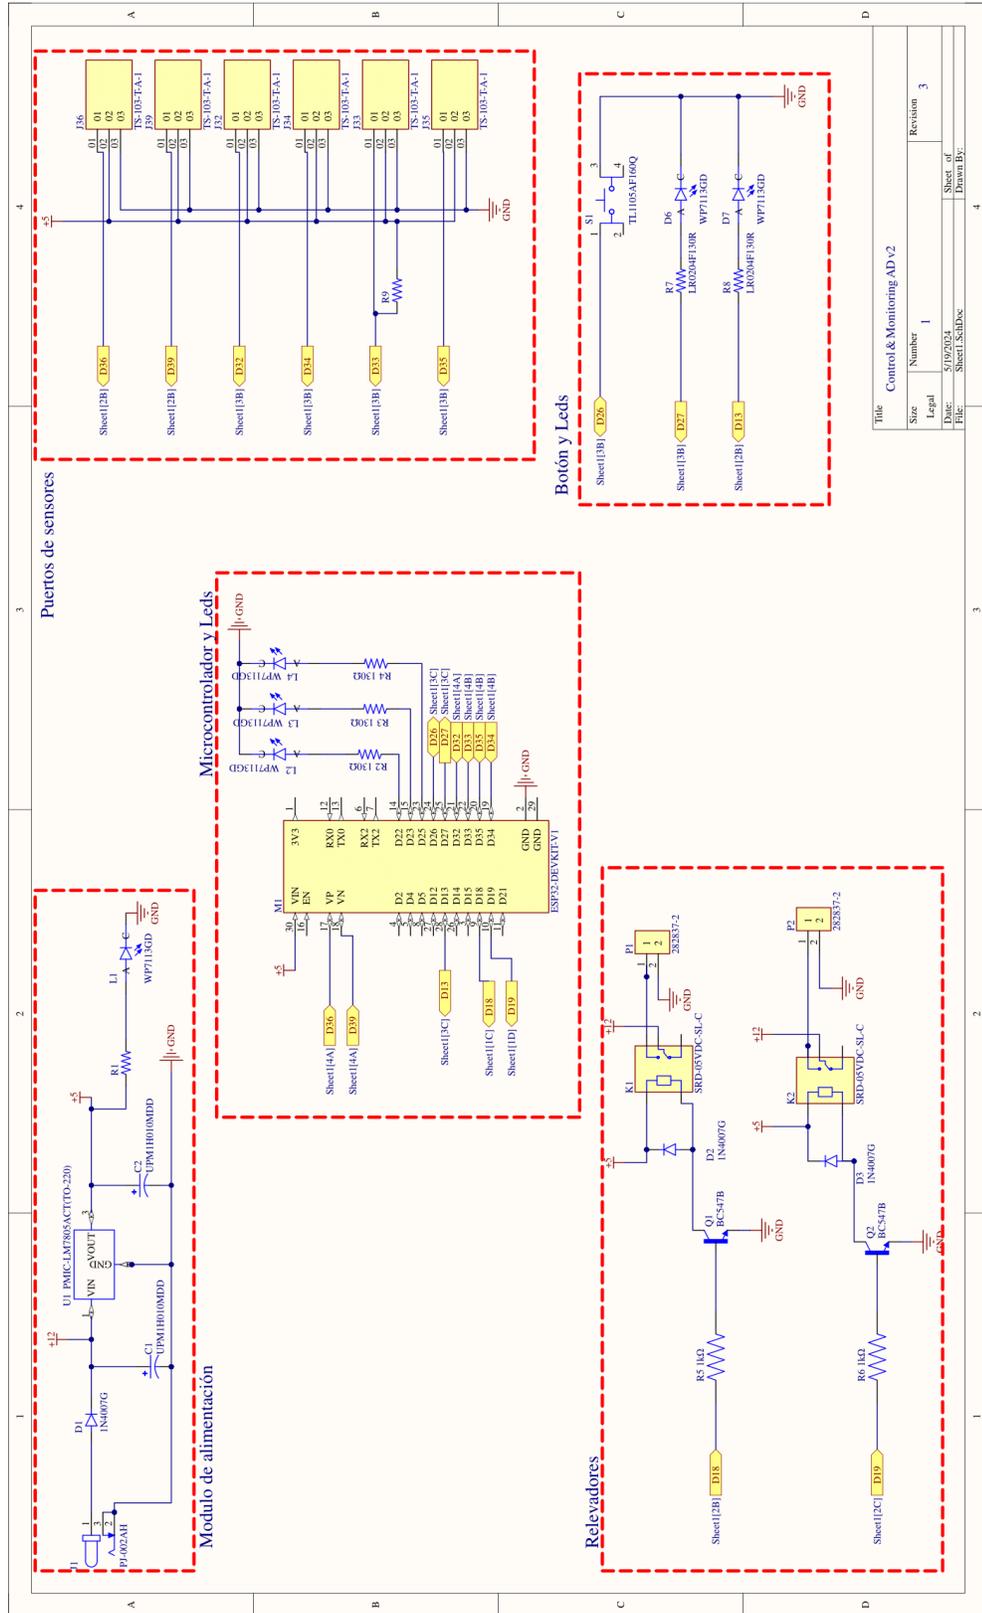


Figura A 10. Diagrama esquemático de la PCB v2.

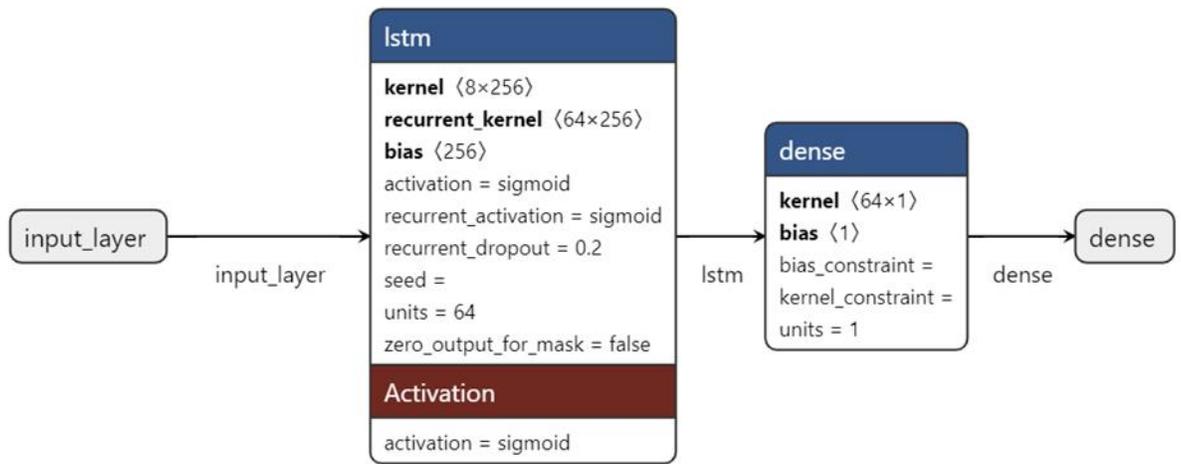


Figura A 11. Diagrama de la arquitectura del soft sensor.