

## Aplicación de un modelo híbrido de optimización por enjambre de partículas y red neuronal artificial para la predicción de fugas en biodigestores

Application of a hybrid particle swarm and artificial neural network model for prediction of leaks in biodigesters

Rocío Camarena Martínez<sup>1</sup>, Saraí Camarena Martínez<sup>2</sup>, Jorge Manuel Barrios Sánchez<sup>3</sup>

<sup>1,3</sup>Departamento de Estudios Multidisciplinarios, División de Ingenierías, Campus Irapuato-Salamanca, Universidad de Guanajuato  
r.camarenamartinez@ugto.mx<sup>1</sup>, s.camarena@ugto.mx<sup>2</sup>, jm.barrios.sanchez@ugto.mx<sup>3</sup>

### Resumen

La calidad en los biodigestores es primordial para prevenir fugas y garantizar la integridad del sistema. Las fugas en un biodigestor pueden tener consecuencias significativas, ya que pueden resultar en la liberación de gases o en la contaminación del suelo que puede resultar no solo en la pérdida del biodigestor, sino también en consecuencias de seguridad. En esta investigación se presenta la aplicación de un modelo híbrido que combina la técnica de Optimización por enjambre de partículas junto con una RNA (RNA) para abordar el problema de predecir fugas en biodigestores. Los resultados obtenidos mediante la combinación del PSO y la RNA muestran un desempeño superior en comparación con una RNA tradicional. Esto se comprueba con el coeficiente de determinación ( $R^2$ ) más elevado mejorando de 0.94 a 0.967, indicando una mayor capacidad de la nueva metodología para modelar y predecir los datos.

**Palabras clave:** Biodigestor, Calidad, Geomembrana, Optimización por Enjambre de Partículas, Red Neuronal Artificial, Proceso de Termofusión.

### Introducción

Los biodigestores desempeñan un papel fundamental en la sostenibilidad ambiental y en la gestión de residuos orgánicos. Asimismo son sistemas herméticamente cerrados diseñados para la producción de biogás a partir de residuos agrícolas, estiércol o efluentes industriales (Guimarães, 2018). Cuando se opera el biodigestor los desechos se descomponen mediante un proceso llamado digestión anaeróbica, durante este proceso, se producen gases, donde principalmente se encuentran el metano ( $CH_4$ ) y dióxido de carbono ( $CO_2$ ), como subproductos (Flesch, 2011). Los biodigestores deben construirse bajo un estricto control de calidad para prevenir las fugas de estos gases. En caso de que se produzca una fuga, los gases escapan del sistema de manera descontrolada, lo que no solo puede resultar en la pérdida del biodigestor, sino también en consecuencias ambientales y de seguridad significativas. La liberación de  $CH_4$ , gas de efecto invernadero, agrava el cambio climático, además que la acumulación de este en concentraciones peligrosas puede llevar a un riesgo de explosión que comprometa la seguridad del operador. Para prevenir las fugas en los biodigestores es necesario conocer a fondo el proceso de termofusión de estos. Se conoce como proceso de termofusión en los biodigestores a la técnica de ensamblar con calor la materia prima principal del biodigestor conocida como las geomembranas (Figura 1) ya sea con una selladora de cuña o una extrusora (Vea Figura 2) Este proceso crea una conexión hermética y resistente evitando fugas de gases o líquidos en el sistema. Sin embargo, la termofusión ha sido un desafío persistente debido a que es el proceso en la manufactura del biodigestor donde se presenta la mayor cantidad de defectos. La durabilidad y la capacidad de mantener una integridad hermética en el biodigestor, es esencial el manejo eficiente de los gases producidos. Por tanto es necesario llevar un control estricto de su calidad que minimice la tasa de defectos. Una de las maneras de prevenir defectos es con modelos de predicción que ayuden a los operadores a la toma correcta de decisiones que permitan disminuir la variabilidad en el proceso de termofusión.



Figura 1. Biodigester elaborado con geomembrana.  
Fuente: EnergyMet (2018).



Figura 2. Maquinaria usada para proceso de termofusión del biodigester.  
Fuente: Elaboración propia.

La integración de la Inteligencia Artificial (IA) en la industria de la energía ha hecho un cambio significativo para la predicción y mejora de la calidad de los procesos (Ahmad, 2021). Actualmente en la industria la predicción desempeña un papel esencial para la toma de decisiones informadas, la optimización de procesos y la reducción de errores. Una de las técnicas de IA para predicción son las RNA. Estas son una de las aplicaciones de modelado más potentes que se puede utilizar para estimar, predecir, tomar decisiones o modelado entre técnicas estadísticas y analíticas (Ahmad, 2014). Estas, pueden resolver y representar sistemas donde sus ventajas es la no linealidad, que proporciona flexibilidad computacional en comparación con el método de regresión lineal proporcionando un rendimiento de predicción preciso de la variable deseada (Jianjun, 2002). Las RNA se han usado para resolver problemas de predicción de fugas (Mujahid, 2023; Waleed 2019; Abdulshaheed, 2017; Jianbin, 2010; Shahin, 2009) con un mayor grado de precisión en comparación con los métodos existentes, así como resolver problemas complejos de ingeniería más rápidamente. No obstante a pesar de que las RNA tienen la capacidad de modelar relaciones complejas y no lineales entre sus factores influyentes, estas aún presentan limitaciones notables, como el riesgo de quedar atrapadas en mínimos locales. Como solución a estos desafíos, se ha demostrado que la aplicación de algoritmos de optimización, como el Optimizador de Enjambre de Partículas (PSO), puede tener un impacto significativo en el rendimiento de las RNA, como se ha observado en investigaciones previas (Eberhart, 2008). Los algoritmos PSO representan un enfoque estocástico orientado a encontrar mínimos o máximos globales. Su funcionamiento está inspirado en el comportamiento de la naturaleza basado en poblaciones que se pueden utilizar de manera efectiva para ajustar los parámetros de las RNA, con el objetivo de mejorar su rendimiento (Gad, 2022). Recientemente, varios estudios han reportado con éxito la aplicación de enfoques híbridos que combinan PSO con RNA (Shariati 2019; Akbaş 2015; Momeni, 2015; Tonnizam 2014). Sin embargo, hasta el momento, los autores no han encontrado investigaciones relacionadas en el uso del PSO con RNA para modelar el proceso de termofusión de los biodigestores. En investigaciones anteriores realizadas por nuestro equipo de investigación, se generó un modelo utilizando un diseño de experimentos (DOE) factorial y una RNA para predecir las fugas de gas en los biodigestores (Camarena 2023). En este estudio se consideraron las variables de temperatura, velocidad de la maquinaria, temperatura ambiente y el operador. El coeficiente de determinación ( $R^2$ ) de la ecuación generada usando una RNA fue de 0.94376. Por esta razón, en esta investigación, se propone mejorar el sistema inteligente para la predicción de fugas en los biodigestores tipo laguna destinados a climas fríos. Se presenta un modelo híbrido que fusiona el algoritmo PSO y una RNA para incrementar la eficiencia de la RNA. Esta exploración se llevó

a cabo con el fin de contrastar los resultados obtenidos con investigaciones previas realizadas por nuestro equipo de investigación.

## Metodología Propuesta

### 1. Objeto de Estudio

Esta investigación tiene como objetivo fundamental garantizar la soldadura correcta de los biodigestores, lo cual implica la detección y prevención de posibles fugas. Para llevar a cabo esta tarea, se implementa lo que se conoce como prueba de aire. Esta prueba desempeña un papel crucial en la validación de la integridad del proceso de termofusión, la cual tiene el propósito primordial de asegurar la completa ausencia de fugas en el sistema. En este proceso, se aprovecha una característica ventajosa de la maquinaria utilizada para la termofusión: la creación de un canal durante el sellado. Este canal posibilita la introducción de aire presurizado, esencial para llevar a cabo las pruebas de presión de aire. (Observe Figura 3).



Figura 3. Prueba de aire en geomembrana en un canal dejado por el sellador de cuña. Fuente: Elaboración propia.

La prueba de aire tiene como objetivo identificar posibles fugas en los sellos de geomembrana. Para ello, se utiliza un manómetro presurizado que registra la presión, manteniéndola entre 25 y 30 libras por pulgada cuadrada (psi) en las uniones con canales correspondientes. Inicialmente, se toma una medición de presión, y luego se observa durante un período de tiempo especificado. Cualquier diferencia superior a 4 psi entre la medición inicial y final del manómetro sugiere la presencia de una junta frágil o una fuga en el sello de geomembrana. Esto podría indicar que el proceso de termofusión no se ejecutó de manera óptima, requiriendo una inspección o reparación adicional. En contraste, si la diferencia de presión durante la prueba de aire es menor a 4 psi, confirma que no existen fugas en el sello de geomembrana. Este resultado valida la exitosa realización del proceso de termofusión, asegurando la integridad y confiabilidad de las uniones selladas. Para visualizar de mejor manera la prueba de aire se presenta la metodología de este proceso en la Figura 4.

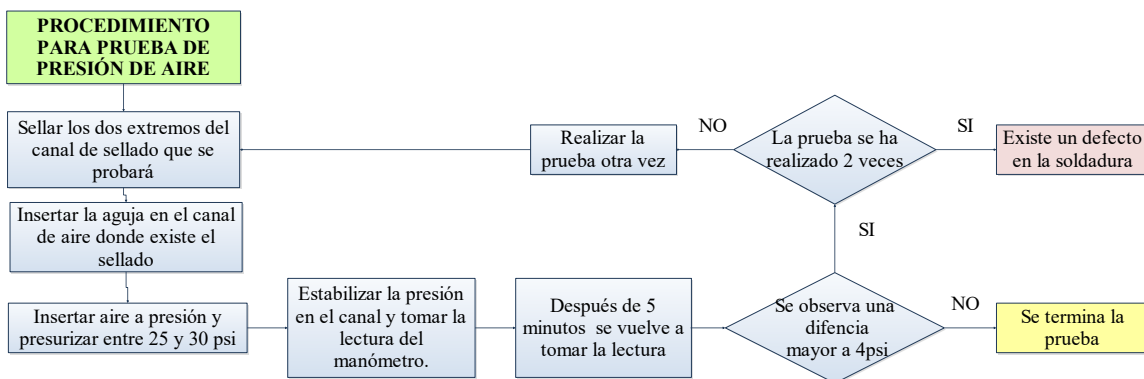


Figura 4. Diagrama de procedimiento para prueba de aire. Fuente: Elaboración propia.

## 2. Recolección y preparación de muestras

Para esta investigación, se tiene como objetivo principal comparar los resultados con investigaciones previas (Camarena, 2023). En esta investigación se recolectaron datos a través de un DOE factorial que consta de 4 factores con 2 niveles y 2 réplicas, centrándose en condiciones de clima frío con una temperatura constante de 9 °C, lo que resultó en un total de 32 pruebas. Para el experimento, se consideraron las variables que influyen en la calidad de la soldadura de las geomembranas las cuales son las siguientes: En primer lugar, se analizó el factor "Operador", el cual se dividió en dos niveles: el primero corresponde a operadores sin capacitación, mientras que el segundo incluye a operadores con capacitación. Además, se evaluaron dos niveles de temperatura para la selladora, a saber, 390°C y 450°C, así como dos niveles de velocidad de la selladora, que fueron 2.6 m/segundo y 3.6 m/segundo. Por último, se registraron dos niveles de temperatura para la extrusora, que fueron 260°C y 290°C. A estas pruebas se les aplicó una transformación arcoseno. Esta transformación normalmente se calcula como  $\arcsin(\sqrt{y})$ , donde  $y$  representa la relación o valor porcentual original. Cabe resaltar que la transformación desempeña un papel importante al normalizar los datos y abordar cualquier anomalía.

El atributo de interés en este análisis es la fuga de gas. Para optimizar la respuesta de este atributo en un DOE utilizando la transformación arcoseno, se promediaron las réplicas del DOE, lo que permitió que los datos representen proporciones o porcentajes que luego se transforman utilizando la función arcoseno. Como resultado final el DOE que consistía en un diseño factorial diseño  $2^4$  con 2 replicas resultó en un total de 16 tratamientos finales. La Tabla 1 muestra el DOE transformado y listo para su análisis.

**Tabla 1.** DOE en condiciones de clima frío después de la transformación arcoseno.

Temperatura clima	Operador	Temperatura Selladora	Velocidad Selladora	Temperatura Extrusora	Prueba de aire Diferencia
9	0	390	2.6	290	0.8691222
9	0	450	3.6	290	0.6154797
9	0	450	3.6	260	0.6154797
9	0	450	2.6	260	0.7016741
9	0	390	3.6	260	0.8691222
9	0	390	2.6	260	0.2928428
9	0	450	2.6	290	0.4205343
9	0	390	3.6	290	0.7853982
9	1	450	2.6	290	0
9	1	390	2.6	260	0.2928428
9	1	450	2.6	260	0
9	1	390	3.6	260	0
9	1	450	3.6	260	0.5235988
9	1	390	2.6	290	0.2928428
9	1	450	3.6	290	0
9	1	390	3.6	290	0

Fuente: Elaboración propia.

Con estos datos disponibles, se procede a utilizar la RNA para modelar y predecir cómo diferentes factores afectan la fuga de gas en nuestros sistemas. Los resultados de este análisis brindarán a los operadores información valiosa que les permitirá tomar decisiones informadas y estratégicas.



### 3. Redes Neuronales Artificiales

Las RNA, como un método sólido de análisis de datos, han demostrado desempeñar funciones similares a los sistemas biológicos presentes en humanos. Son particularmente valiosas para descubrir relaciones en conjuntos de datos complejos y ruidosos, estableciendo conexiones entre las entradas y las salidas. (Oludare, 2018). Entre los tipos más simples y confiables de RNA se encuentra el Perceptrón Multicapa, que comprende una capa de entrada, una o varias capas ocultas y una capa de salida.

En el estudio actual, se eligió que la RNA tuviera una estructura de de tres capas. La estructura utilizada se visualiza en la Figura 5.




Figura 5. Estructura de RNA utilizada. Fuente: Elaboración propia.

Las RNA aprenden a través del ajuste de los pesos y sesgos de sus conexiones neuronales. Inicialmente, los pesos y sesgos se establecen aleatoriamente o mediante algún método de inicialización. Luego, durante la fase de entrenamiento, la RNA se expone a un conjunto de datos de entrada y se compara la salida predicha con la salida deseada. Cualquier discrepancia entre la salida predicha y la deseada se utiliza para calcular un error. En las unidades de procesamiento, las entradas \$X\_i\$ se multiplican por los pesos \$W\_{ij}\$ correspondientes a un nodo oculto \$y\_j\$. Luego, se suman todos los productos \$W\_{ij} \times X\_i\$, a lo cual se agrega un valor de sesgo \$b\_j\$ y finalmente se aplica una función de transferencia adecuada (\$f\$). Esta operación se puede expresar de la siguiente manera, como se muestra en la Ecuación (1).

$$y_j = f(\sum W_{ij}X_i + b_j) \quad (1)$$

En el proceso de aprendizaje, el error se calcula mediante la Ecuación (2). La salida prevista en relación con la salida real se propaga hacia atrás para ajustar todos los valores de peso y sesgo.

$$E = \frac{1}{n} \sum_{i=1}^n (Y_i - O_i)^2 \quad (2)$$

Dónde \$Y\_i\$ es la salida prevista de la red y \$O\_i\$ es el resultado esperado.

Para el desarrollo de la RNA propuesta se utilizó el software MATLAB R 2020b®. Las entradas introducidas para entrenar la red fueron las características que influyen en la calidad de la soldadura en los biodigestores. La RNA tuvo 3 etapas: entrenamiento, validación y prueba. En la etapa de entrenamiento, las pesas se ajustaban automáticamente hasta lograr los resultados deseados. La proporción de patrones para cada etapa de evaluación de RNA fue del 80% para capacitación, 15% para validación y 15% para pruebas.

### 4. Optimización de Enjambre de partículas (PSO)

PSO, como algoritmo evolutivo confiable y eficiente, puede resolver problemas de optimización complejos y no lineales (Mendes, 2002). Este algoritmo basado en inteligencia de enjambre resolvió satisfactoriamente los problemas de optimización global en comparación con otros métodos (Hasanipanah, 2016). PSO es una técnica evolutiva basada en métodos sociales como la formación de bancos de peces y bandadas de aves (Valdez, 2011). Según el concepto matemático de PSO, tres parámetros principales desempeñan funciones importantes: posición, velocidad y aptitud física. Los pasos principales de PSO para resolver cualquier problema de optimización son los siguientes (Alizamir, 2018):

1. Inicializar una población de individuos (partículas) con velocidades y posiciones aleatorias en el dominio del problema.

2. Calcular el valor de aptitud para todas las partículas.
3. Investigación de la aptitud de las partículas.
4. Actualización de la velocidad y posición de las partículas utilizando las Ecuaciones (3) y (4).

$$V_{ij}^t = X[\omega v_{ij}^{t-1} + c_1 r_1 (p_{ij}^{t-1} - x_{ij}^{t-1}) + c_2 r_2 (G_j^{t-1} - x_{ij}^{t-1})] \quad (3)$$

$$X_{ij}^t = x_{ij}^{t-1} + v_{ij}^{t-1}$$

Donde  $r_1$  y  $r_2$  son números aleatorios,  $c_1$  y  $c_2$  representan constantes de aceleración;  $\omega$ ,  $\chi$ ,  $p^t$  y  $G^t$  indican peso de inercia, coeficiente de restricción,  $p_{best}$  y  $g_{best}$ , respectivamente. La aptitud de cada partícula se calcula mediante el error cuadrático medio de la red neuronal de la siguiente manera:

$$f(W_i) = \frac{1}{s} \sum_{k=1}^s \left[ \sum_{l=1}^0 \{t_{kl} - p_{kl}(w_i)\}^2 \right]$$

Donde  $f$  es la función de aptitud,  $t_{kl}$  y  $p_{kl}$  son valores observados y predichos basados en  $w_i$ , respectivamente. El beneficio más importante del enfoque PSO es su bajo costo computacional y su codificación simple (38). Dado que el algoritmo PSO se demuestra que funciona con precisión este se usa como propuesta para mejorar los resultados de la RNA. Después de construir la RNA utilizando datos seleccionados de entrada y salida, aplicamos un enfoque que combina el PSO para optimizar los pesos de la red. En este proceso, cada partícula en el PSO representa un conjunto de pesos para la RNA. Cada partícula en el PSO se actualiza iterativamente, ajustando su posición y velocidad en función del rendimiento actual y de referencias pasadas. La posición óptima local ( $p_{best}$ ) y global ( $g_{best}$ ) se determinan teniendo en cuenta el rendimiento de las partículas en la búsqueda. Este proceso de actualización continúa durante un número fijo de generaciones. El objetivo es que las partículas converjan hacia una solución que minimice la función de aptitud de la RNA, que mide la discrepancia entre las salidas predichas por la red y los valores reales. Esta optimización persigue la reducción del error. Una vez completado el proceso de entrenamiento, la RNA optimizada se considera lista para su uso, ya que sus pesos han sido ajustados para que las salidas se ajusten de manera óptima a las entradas proporcionadas (Khatir, 2019).

## Resultados

En el estudio actual, se aplicó PSO para entrenar la RNA para mejorar la convergencia y el rendimiento del modelo predictivo. Se aplicaron los mismos conjuntos de entrenamiento y prueba para desarrollar el enfoque RNA-PSO. Además, se seleccionaron siete neuronas ocultas. Para investigar la precisión del rendimiento del modelo, se utilizó el indicador estadístico  $R^2$ . Los modelos ANN-PSO y la RNA se compararon como se muestra en las Figuras 6 a 7.

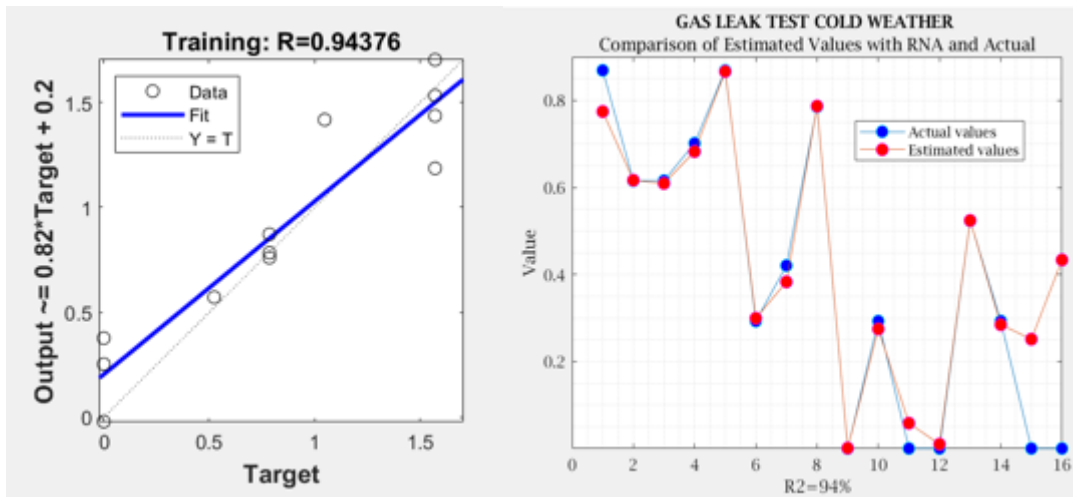


Figura 6. Análisis comparativo RNA tradicional de los valores estimados y reales para la prueba de fuga de gas.  
 Fuente: Elaboración propia.



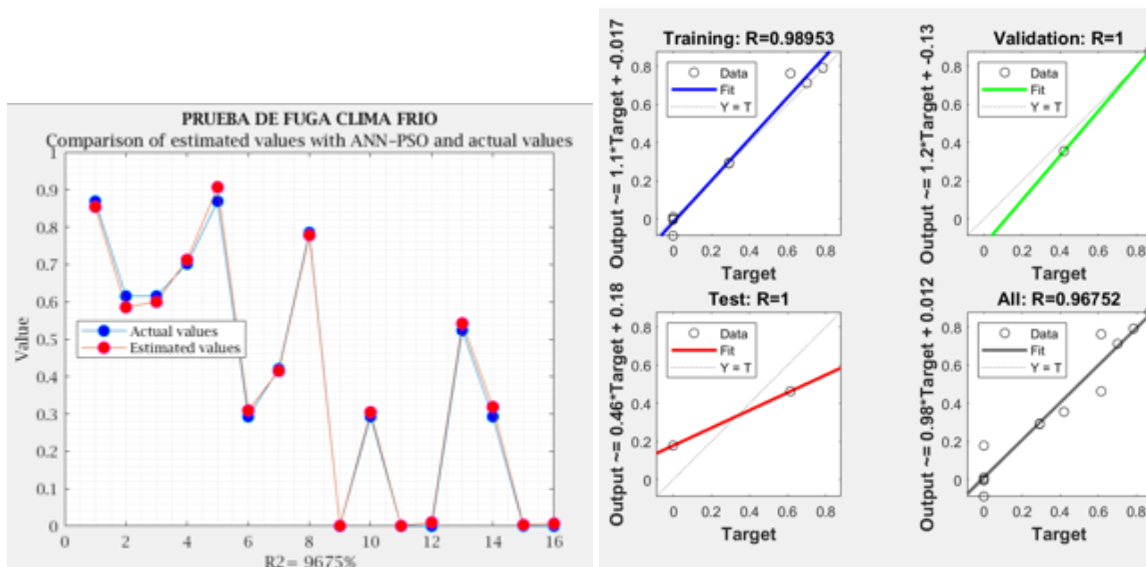


Figura 7. Análisis comparativo con modelo híbrido RNA-PSO de los valores estimados y reales para la prueba de fuga de gas a temperatura fría  
 Fuente: Elaboración propia.

La calidad de los biodigestores desempeña un papel fundamental para la prevención de fugas y en la garantía de la integridad de este. Las fugas en las geomembranas de los biodigestores pueden tener repercusiones significativas, incluyendo la liberación de gases y la contaminación del suelo, lo que no solo conlleva la pérdida del biodigestor, sino también preocupaciones de seguridad. En este estudio, hemos presentado la aplicación de un modelo híbrido que combina la técnica de PSO con una RNA para abordar el problema de predecir fugas en biodigestores. Los resultados obtenidos a través de esta combinación de PSO y RNA demuestran un rendimiento superior en comparación con el uso de una RNA tradicional. Esto se evidencia en el  $R^2$ , que aumentó de 0.94 a 0.967, indicando una mayor capacidad de la nueva metodología para modelar y predecir los datos de manera efectiva. En consecuencia, esta investigación ofrece una perspectiva prometedora para mejorar la detección y prevención de fugas en biodigestores, contribuyendo así a ayudar a los operadores de los biodigestores a tomar decisiones que promuevan la seguridad y eficiencia de los biodigestores.

## Referencias

- Abdulshaheed A., Mustapha F., & Ghavamian A., (2017). A pressure-based method for monitoring leaks in a pipe distribution system: A Review. *Renew. Sustain.* 69 902–911.
- Ahmad A.S, Hassan M.Y., Abdullah M.P., Rahman H.A., Hussin F., Abdullah H., & Saidur R. (2014). A review on applications of ANN and SVM for building electrical energy consumption forecasting. *Renewable and Sustainable Energy Reviews*, 33, 102-109, ISSN 1364-0321, <https://doi.org/10.1016/j.rser.2014.01.069>.
- Ahmad T., Zhang D., Huang C., Hongcai Z., Ningyi D., Yonghua S., & Huanxin C. (2021). Artificial intelligence in sustainable energy industry: Status Quo, challenges and opportunities. *Journal of Cleaner Production*, 289, 125834, ISSN 0959-6526, <https://doi.org/10.1016/j.jclepro.2021.125834>.
- Akbaş H., Bilgen B., & Turhan AM. (2015). An integrated prediction and optimization model of biogas production system at a wastewater treatment facility. *Bioresour Technol* 196:566–576.
- Alizamir M., & Sobhanardakani S. (2018). An Artificial Neural Network - Particle Swarm Optimization (ANN-PSO) Approach to Predict Heavy Metals Contamination in Groundwater Resources. *Jundishapur J Health Sci.* 2018;10(2): e67544. <https://doi.org/10.5812/jjhs.67544>.
- Camarena-Martinez R., Baeza-Serrato R., & Lizarraga-Morales RA. (2023). Optimization of Welding Process of Geomembranes in Biodigesters Using Design of Factorial Experiments. *Energies*, 16(18):6583. <https://doi.org/10.3390/en16186583>



- Eberhart RC., & Shi Y. (2008). Evolving artificial neural networks. In: Proceedings of the international conference on neural networks and brain, PL5–PL13.
- Flesch T.K., Raymond L., Desjardins., & Worth D. (2011). Fugitive methane emissions from an agricultural biodigester. *Biomass and Bioenergy*, 35, Issue 9, 2011, 3927-3935, ISSN 0961-9534, <https://doi.org/10.1016/j.biombioe.2011.06.009>.
- Gad, A.G. (2022) Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review. *Arch Computat Methods Eng* 29, 2531–2561. <https://doi.org/10.1007/s11831-021-09694-4>.
- Guimarães, CDS., Maia D., & Serra EG. (2018). Construction of Biodigesters to Optimize the Production of Biogas Anaerobic. Co-Digestion of Food Waste and Sewage. *Energies*, 11(4):870. <https://doi.org/10.3390/en11040870>
- Hasanipanah M., Noorian-Bidgoli M., Armaghani DJ., & Khamesi H. (2016). Feasibility of PSO–ANN model for predicting surface settlement caused by tunneling. *Eng Comput*, 32(4):705–715
- Jianbin Z., Jiewen T., & Yongqiang S. (2010). An ANN model for predicting level ultimate bearing capacity of PHC pipe pile. *Earth and Space*, pp 3168–3176
- Jianjun X., Yagoub M. C. E., Runtao D., & Qi-Jun Z. (2002). Neural-based dynamic modeling of nonlinear microwave circuits. *IEEE Transactions on Microwave Theory and Techniques*, 50, no. 12, pp. 2769-2780, doi: 10.1109/TMTT.2002.805192.
- Khatir, S., Tiachacht, S., Cuong-LeThanh, Quoc Bu, T., Abdel Wahab, M., (2019). Damage assessment in composite laminates using ANN-PSO-IGA and Cornwell indicator. *Composite Structures*, doi: <https://doi.org/10.1016/j.compstruct.2019.111509>
- Mendes R., Cortez P, Rocha M., & Neves J. (2002). Particle swarms for feedforward neural network training. In: Proceedings of the 2002 international joint conference on neural networks. IEEE, New York, 1895–1899.
- Momeni E., Jahed Armaghani D., Hajihassani M., & Amin MFM. (2015). Prediction of uniaxial compressive strength of rock samples using hybrid particle swarm optimization-based artificial neural networks. *Measurement* 60:50–63
- Mujahid A., & Sai Hin L. (2023). Artificial intelligent techniques for prediction of rock strength and deformation properties. A review, *Structures*, 55, 1542-1555, ISSN 2352-0124, <https://doi.org/10.1016/j.istruc.2023.06.131>.
- Oludare IA., Aman J., Abiodun E.O., Kemi V. D., Nachaat A.M., & Humaira A. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon* 4 e00938. doi: 10.1016/j.heliyon.2018. e00938
- Shahin MA., Jaksa MB., & Maier HR. (2009). Recent advances and future challenges for artificial neural systems in geotechnical engineering applications. *Adv Artif Neural Syst*. doi:10.1155/2009/308239
- Shariati M., Mafipour MS., Mehrabi P., Bahadori A., Zandi Y., Salih MNA., Nguyen H., Dou J., Song X., & Poinjian S. (2019). Application of a hybrid artificial neural network-particle swarm optimization (ANN-PSO) model in behavior prediction of channel shear connectors embedded in normal and high-strength concrete. *Appl Sci* 9(24):5534–21.
- Tonnizam Mohamad E., Jahed Armaghani D., Momeni E., & Alavi Nezhad Khalil Abad S.V. (2014). Prediction of the unconfined compressive strength of soft rocks: a PSO-based ANN approach. *Bull Eng Geol Environ*. doi:10.1007/s10064-014-0638-0
- Valdez F., Melin P., & Castillo O. (2011). An improved evolutionary method with fuzzy logic for combining Particle Swarm Optimization and Genetic Algorithms. *Applied Soft Computing*, 11, Issue 2, 2625-2632, ISSN 1568-4946, <https://doi.org/10.1016/j.asoc.2010.10.010>.
- Waleed D., Mustafa S.H., Mukhopadhyay S., Abdel-Hafez M.F, Jaradat M.A.K., Dias K.R., Arif F., & Ahmed J.I. (2019). An in-pipe leak detection robot nn based leak verification system. *Sens. J.*, 19 (3) (2019), pp. 1153-1165

