

Modelado y optimización de la fermentación en estado sólido: El poder de la inteligencia artificial en procesos biotecnológicos

Hugo Beatriz-Cuellar*, María Aurora Martínez-Trujillo, Isabel de la Luz Membrillo-Venegas

Tecnológico Nacional de México: Tecnológico de Estudios Superiores de Ecatepec. Ecatepec, Estado de México, México

* Autor de correspondencia: 202322187@tese.edu.mx

Artículo de divulgación científica

Recibido: 27 de octubre de 2024

Aceptado: 20 de noviembre de 2024

Publicado: 14 de diciembre de 2024

DOI: <https://doi.org/10.56845/terys.v3i1.304>

Resumen: Este trabajo describe las características, los beneficios y el procedimiento del modelado y la optimización de procesos de fermentación en estado sólido (FES) mediante sistemas de inteligencia artificial (IA). En este artículo se describen las características de las redes neuronales artificiales para modelar un proceso; así como del algoritmo genético y la optimización por enjambre de partículas para determinar los valores óptimos de las variables independientes del proceso. Además, se señalan los requerimientos para implementar estos sistemas de IA en un proceso de FES. La propuesta se basa en la facilidad que supone el hecho de que estos sistemas de IA no requieren operaciones matemáticas complejas, ya que utilizan conceptos e ideas de la naturaleza para solucionar problemas a partir del uso de un conjunto de datos o medidas del proceso. Como su funcionamiento es simple de entender e implementar, el uso de estas técnicas de IA en la FES puede ser de gran utilidad para predecir de manera más precisa el comportamiento del proceso, reducir los errores, ahorrar tiempo y hacer un uso más eficiente de los recursos disponibles.

Palabras clave: fermentación en estado sólido, modelado, optimización, algoritmos evolutivos, inteligencia artificial

Introducción

La producción de combustibles fósiles, incendios forestales, y el exceso de residuos agrícolas y orgánicos son una fuente significativa de contaminación ambiental, generando gases de efecto invernadero y partículas tóxicas al descomponerse o quemarse (Ajibade *et al.*, 2020). En lo que respecta a los residuos agrícolas y orgánicos, estos pueden transformarse en recursos valiosos mediante la FES, un proceso en el que los microorganismos toman a estos desechos como fuente de carbono y energía, y los transforman en productos valiosos como enzimas, biocombustibles, pigmentos, bioplaguicidas, ácidos orgánicos, entre otros (Oiza *et al.*, 2022). Durante su desarrollo, la FES utiliza bajas cantidades de agua y energía y tiene baja probabilidad de contaminación. Además, los elementos involucrados en el desarrollo del proceso suelen ser de bajo costo, y en general tiene poco impacto ambiental (Vandenberghe *et al.*, 2021). Sin embargo, la baja eficiencia o productividad es el principal problema que limita el uso de la FES, ya que no cumple con los requisitos del mercado de una manera rentable (Kumar *et al.*, 2021). Por lo anterior, se deben buscar estrategias para mejorar la productividad, el desempeño y la rentabilidad del proceso de fermentación. En este contexto, resulta útil modelar el desarrollo de la fermentación y/o determinar los parámetros o factores óptimos del proceso. Las herramientas más comunes para ello son las técnicas estadísticas, como la metodología de superficie de respuesta. Sin embargo, estas metodologías presentan incertidumbre, errores de estimación, problemas para alcanzar los valores óptimos y modelos complejos o con poco sustento teórico (Hadiyat *et al.*, 2022).

Una alternativa que se ha estado utilizando recientemente para modelar y optimizar los procesos de FES son las técnicas basadas en la IA. Las redes neuronales artificiales, y los métodos de optimización inspirados en la naturaleza, como el enjambre de partículas y un algoritmo genético, se han utilizado con éxito en sectores como la salud, finanzas, transporte, educación, industria, y ciberseguridad, mostrando excelentes resultados (Dastres & Soori, 2021). Lo anterior se debe a que los sistemas de IA minimizan los errores en procesos críticos, mejoran la precisión y optimizan el uso de los recursos (Angelov *et al.*, 2021). En este artículo, se describen las características de las herramientas de IA y se analiza el procedimiento para modelar y optimizar la FES mediante estas herramientas.

Desarrollo

La FES es un proceso que utiliza materiales sólidos (como bagazo de caña de azúcar, cáscaras de frutas, pulpa de frutas, paja de trigo, restos de café, etc.) como sustrato para el cultivo y desarrollo de microorganismos, tales como bacterias, hongos filamentosos y levaduras. Durante este proceso, los microorganismos metabolizan el sustrato y generan

diferentes productos de interés para diversos procesos. La producción final obtenida mediante este tipo de fermentación está condicionada principalmente por las características del sustrato y los microorganismos. Adicionalmente, la producción final depende de diversos factores o parámetros, tales como el pH del medio, la temperatura de incubación, la humedad inicial del sustrato, el tiempo de incubación, la aireación (incorporación de aire al proceso), el tamaño de partícula del sustrato, entre otros (Taherzadeh *et al.*, 2022).

En este contexto, los factores de operación que determinan el desarrollo de la FES se definen como las variables independientes, y la producción final generada durante el desarrollo del cultivo como la variable o variables independientes del proceso (producción de enzimas, biocombustibles, ácidos orgánicos, etc.). El control de los parámetros o variables independientes es un aspecto de gran importancia, debido a su impacto en el proceso (Mitchell *et al.*, 2006). Para esto, se puede modelar el funcionamiento y optimizar el proceso de fermentación. El modelado se refiere a encontrar una regla de correspondencia o relación entre las variables de entrada y salida de un proceso. Por otra parte, la optimización se refiere a obtener los valores de las variables independientes con los que sea posible obtener la máxima o mínima producción de algún producto, utilizando la menor cantidad de recursos y tiempo (Martins & Ning, 2021). Con base en ambas definiciones, se propone utilizar los sistemas de IA antes mencionados, para lo cual revisaremos a detalle sus características.

Red neuronal artificial

Una red neuronal artificial es un sistema que imita el funcionamiento del cerebro humano, y permite a una máquina "aprender" información y reconocer patrones a partir de un conjunto de datos. La red está conformada por: la capa de entrada, que recibe los datos de las variables independientes; las capas ocultas, que almacenan la mayor parte del conocimiento de un proceso; y la capa de salida, que representa la respuesta o las variables dependientes. La Figura 1 muestra la estructura de una red neuronal artificial, donde X_1, \dots, X_n representan parámetros como temperatura, humedad inicial, tiempo de fermentación, etc., y Y_1, \dots, Y_n representan productos como la producción de enzimas, biocombustibles, ácidos orgánicos, etc. Para entrenar o ajustar la red, se necesita un conjunto de datos o mediciones de las variables independientes y dependientes a lo largo del proceso. Estos datos se pueden obtener mediante el desarrollo de un diseño de experimentos, en el que se pruebe la variación de los valores que toman las variables dependientes en función de los valores que toman las variables independientes. Las principales ventajas de una red neuronal artificial son las siguientes: pueden tener múltiples entradas y múltiples salidas, no requieren el modelo matemático del proceso, únicamente necesitan ecuaciones matemáticas simples para su implementación, entre otras (da Silva *et al.*, 2017). En el caso de la FES, una red neuronal artificial puede "aprender" de datos experimentales y prever cómo responderá el proceso ante distintos cambios. Imaginemos una red neuronal como un chef que aprende a perfeccionar una receta probando diferentes combinaciones de ingredientes: a través de la repetición y el análisis de los resultados, el chef descubre las proporciones perfectas para optimizar el platillo.




Figura 1. Estructura de una red neuronal artificial.

Algoritmo genético

Un algoritmo genético es una técnica de optimización inspirada en los principios de la selección natural y la genética. Se desarrolla en diferentes etapas, tales como evaluación, selección, emparejamiento, cruce y mutación. El concepto más importante de un algoritmo genético es el cromosoma, el cual está conformado por las variables independientes del proceso y representa una posible solución al problema de optimización. La Figura 2 muestra una representación gráfica del funcionamiento de un algoritmo genético. Primero se genera una población de cromosomas o individuos (la población puede estar conformada con diferentes colores). La selección de los mejores individuos se determina mediante el modelo del proceso (se observan los colores y se eligen los que tienen mayor intensidad). Posteriormente,

se realiza una combinación de las variables independientes de los mejores individuos para crear nuevos individuos (se combinan los colores para generar nuevos colores). Finalmente, se realiza la modificación o mutación de las características de algunos individuos para mantener la diversidad genética o explorar toda la región experimental (se realiza el cambio de color de algunos individuos). El procedimiento descrito se debe realizar hasta obtener los valores




Figura 2. Representación de las etapas de un algoritmo genético.

óptimos de las variables independientes. Las principales ventajas de un algoritmo genético son las siguientes: se puede utilizar con procesos lineales (donde la salida es directamente proporcional a la entrada) y procesos no lineales (en los que no existe una relación proporcional entre la salida y la entrada); únicamente se necesitan ecuaciones matemáticas simples para su implementación; y se puede utilizar con procesos de múltiples entradas y múltiples salidas, entre otras (Haupt & Haupt, 2004). Como los criadores que eligen y cruzan las mejores semillas, estos algoritmos determinan la condición de cada variable del proceso, como la temperatura o el pH, para obtener un producto con la mayor calidad. Así, el proceso de fermentación podría optimizarse a través de generaciones de ajustes, que simulan la selección natural.

Optimización por enjambre de partículas

La optimización por enjambre de partículas está inspirada en el comportamiento colectivo y características sociales de organismos vivos (bandadas de pájaros, bancos de peces, colonias de hormigas, etc.) cuando buscan algún objetivo (comida, migración, etc.). El concepto más importante de esta técnica es la partícula, que representa a un organismo vivo dentro de un enjambre, está conformada por las variables independientes del proceso y constituye una solución al problema de optimización. Primero, se genera aleatoriamente un conjunto de partículas que estén distribuidas uniformemente en la región experimental, como se muestra en la Figura 3(a), donde cada punto rojo representa una partícula. A continuación, cada partícula se debe evaluar mediante el modelo del proceso para determinar la mejor posición encontrada por cada partícula (por ejemplo, la fuente de alimentos más grande en la posición actual de un organismo vivo) y la mejor posición encontrada por una partícula del enjambre (por ejemplo, la fuente de alimentos más grande que se ha encontrado en la región experimental). Estos dos parámetros se utilizan para ajustar la posición y la velocidad de las partículas. El procedimiento descrito se debe realizar hasta obtener los valores óptimos de las variables independientes, como se muestra en la Figura 3(b), donde los puntos azules corresponden a la solución óptima.

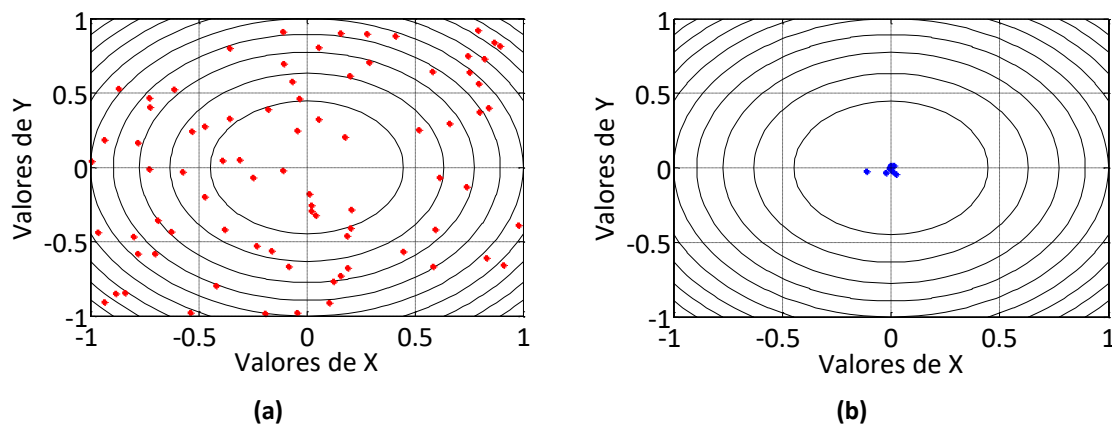


Figura 3. Optimización por enjambre de partículas: (a) posición inicial de las partículas y (b) posición final de las partículas.

Las principales ventajas de la optimización por enjambre de partículas son las siguientes: se puede utilizar para procesos lineales y no lineales, utiliza ecuaciones matemáticas simples para su implementación, se pueden utilizar con procesos de múltiples entradas y múltiples salidas, entre otras (Bansal, 2019).

Modelar y optimizar un proceso de fermentación en estado sólido con IA

El procedimiento para modelar y optimizar un proceso de FES mediante sistemas de IA es el siguiente: el primer paso es definir las variables independientes que se optimizarán. El segundo paso es definir las respuestas del proceso, es decir, las variables dependientes. El tercer paso es diseñar y llevar a cabo un diseño de experimentos, para recoger datos de cómo varían los resultados de acuerdo con diferentes combinaciones de las variables independientes (Gutiérrez Pulido & de la Vara Salazar, 2008). El cuarto paso consiste en utilizar los resultados de los experimentos para obtener el modelo del proceso mediante la red neuronal artificial. El quinto paso es determinar la técnica de optimización que se utilizará, decidiendo entre algoritmos genéticos o de enjambre de partículas. El sexto paso es usar en conjunto las redes neuronales artificiales y la técnica de optimización para determinar los valores óptimos de las variables independientes. El séptimo paso consiste en comprobar los resultados obtenidos mediante pruebas experimentales del proceso de FES. La Tabla 1 describe y ejemplifica el procedimiento para modelar y optimizar un proceso de fermentación mediante IA.

El uso de sistemas de IA para optimizar el desarrollo de la FES tiene múltiples beneficios: al minimizar los recursos necesarios, se reducen los costos de producción; los sistemas de IA utilizados evolucionan constantemente, lo que permite optimizar el proceso con una alta precisión; y finalmente, estas técnicas de optimización pueden ajustarse a diferentes tipos de sustratos y objetivos del proceso. Todo lo anterior permitiría ampliar la aplicabilidad de la FES para el desarrollo de procesos en la industria (Bezerra *et al.*, 2021; Sales de Menezes *et al.*, 2021).

Tabla 1. Procedimiento para modelar y optimizar un proceso de fermentación en estado sólido con IA.

Paso	Nombre	Descripción
1	Definir variables independientes	Parámetros que afectan la respuesta durante el desarrollo del proceso (pH, temperatura, humedad, etc.)
2	Definir variables dependientes	Productos finales (enzimas, biocombustibles, bioplaguicidas etc.)
3	Diseño de experimentos	Diseño Box-Behnken, Diseño compuesto central, entre otros.
4	Modelar el proceso	Entrenamiento de la red neuronal artificial (ajustar sus parámetros)
5	Definir la técnica de optimización	Algoritmo genético u optimización de enjambre de partículas
6	Optimizar el proceso	Valores óptimos de los parámetros (temperatura, humedad, etc.)
7	Validar los resultados	Producción final a partir de los valores óptimos (enzimas, etc.)

Conclusiones

Debido a la importancia y los beneficios de la FES, se debe buscar métodos para analizar, modelar y optimizar este proceso. Por lo tanto, se describe el procedimiento y las características de sistemas de IA para modelar y optimizar el proceso de fermentación de manera sostenible, rentable y con el mayor grado de precisión. En este caso, la aplicación de las redes neuronales artificiales facilita el análisis del funcionamiento de la fermentación debido a que pueden aprender correctamente la dinámica del proceso o modelar toda la región experimental a partir de los resultados obtenidos de un diseño experimental. También, la aplicación del algoritmo genético o la optimización de enjambre de partículas facilita la optimización, es decir, con su aplicación se puede obtener la máxima producción posible de un proceso utilizando la menor cantidad de recursos. Por otro lado, mejorar la eficiencia del proceso de fermentación puede incrementar y promover su aplicación para obtener productos de valor agregado, los cuales se utilicen en un mayor número de aplicaciones. Adicionalmente, se podría reducir la contaminación del medio ambiente provocada por la acumulación de los residuos agrícolas, forestales y orgánicos, ya que se ofrece una alternativa viable para transformar y utilizar estos materiales como sustrato de la FES. Finalmente, la investigación futura podría centrarse en explorar la aplicabilidad de estas técnicas en otros tipos de fermentación o en procesos biotecnológicos complejos, avanzando hacia una industria más verde y sustentable.

Agradecimientos y financiamiento: Hugo Beatriz Cuellar (folio: EESP2024-0037) agradece al Consejo Mexiquense de Ciencia y Tecnología por la beca otorgada, y Aurora Martínez Trujillo agradece a los proyectos del TecNM, clave 20239.24-PD, y al CONAHCYT, clave CBF2023-2024-741.

Bibliografía

- Ajibade, F. O., Adelodun, B., Lasisi, K. H., Fadare, O. O., Ajibade, T. F., Nwogwu, N. A., Sulaymon, I. D., Ugya, A. Y., Wang, H. C., & Wang, A. (2020). Environmental pollution and their socioeconomic impacts. In *Microbe Mediated Remediation of Environmental Contaminants* (pp. 321–354). Elsevier. <https://doi.org/10.1016/B978-0-12-821199-1.00025-0>.
- Angelov, P. P., Soares, E. A., Jiang, R., Arnold, N. I., & Atkinson, P. M. (2021). Explainable artificial intelligence: an analytical review. *WIREs Data Mining and Knowledge Discovery*, 11(5). <https://doi.org/10.1002/widm.1424>.
- Bansal, J. C. (2019). Particle Swarm Optimization. In *Studies in Computational Intelligence* (Vol. 779, pp. 11–23). Springer Verlag. https://doi.org/10.1007/978-3-319-91341-4_2.
- Bezerra, C. O., Carneiro, L. L., Carvalho, E. A., das Chagas, T. P., de Carvalho, L. R., Uetanabaro, A. P. T., da Silva, G. P., da Silva, E. G. P., & da Costa, A. M. (2021). Artificial Intelligence as a Combinatorial Optimization Strategy for Cellulase Production by *Trichoderma stromaticum* AM7 Using Peach-Palm Waste Under Solid-State Fermentation. *BioEnergy Research*, 14(4), 1161–1170. <https://doi.org/10.1007/s12155-020-10234-4>.
- da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). *Artificial Neural Networks*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-43162-8>.
- Dastres, R., & Soori, M. (2021). Artificial Neural Network Systems. *International Journal of Imaging and Robotics (IJIR)*, 2021(2), 13–25. www.ceserp.com/cp-jour.
- Gutiérrez Pulido, H., & de la Vara Salazar, R. (2008). *Análisis y diseño de experimentos* (Segunda edición). McGraw-Hill.
- Hadiyat, M. A., Sopha, B. M., & Wibowo, B. S. (2022). Response Surface Methodology Using Observational Data: A Systematic Literature Review. *Applied Sciences*, 12(20), 10663. <https://doi.org/10.3390/app122010663>.
- Haupt, R. L., & Haupt, S. E. (2004). *PRACTICAL GENETIC ALGORITHMS TEAM LinG-Live, Informative, Non-cost and Genuine !* (2nd ed.). A Wiley-Interscience.
- Kumar, V., Ahluwalia, V., Saran, S., Kumar, J., Patel, A. K., & Singhania, R. R. (2021). Recent developments on solid-state fermentation for production of microbial secondary metabolites: Challenges and solutions. *Bioresource Technology*, 323, 124566. <https://doi.org/10.1016/j.biortech.2020.124566>.
- Martins, J. R. R. A., & Ning, A. (2021). *Engineering Design Optimization*. Cambridge University Press. <https://doi.org/10.1017/9781108980647>.
- Mitchell, D. A., Berovič, M., & Krieger, N. (2006). *Solid-State Fermentation Bioreactors* (D. A. Mitchell, M. Berovič, & N. Krieger, Eds.). Springer Berlin Heidelberg. <https://doi.org/10.1007/3-540-31286-2>.
- Oiza, N., Moral-Vico, J., Sánchez, A., Oviedo, E. R., & Gea, T. (2022). Solid-state fermentation from organic wastes: A new generation of bioproducts. *Processes* (Basel, Switzerland), 10(12), 2675. <https://doi.org/10.3390/pr10122675>.
- Sales de Menezes, L. H., Carneiro, L. L., Maria de Carvalho Tavares, I., Santos, P. H., Pereira das Chagas, T., Mendes, A. A., Paranhos da Silva, E. G., Franco, M., & Rangel de Oliveira, J. (2021). Artificial neural network hybridized with a genetic algorithm for optimization of lipase production from *Penicillium roqueforti* ATCC 10110 in solid-state fermentation. *Biocatalysis and Agricultural Biotechnology*, 31, 101885. <https://doi.org/10.1016/j.bcab.2020.101885>.
- Taherzadeh, M., Ferreira, J., & Pandey, A. (Eds.). (2022). *Current developments in biotechnology and bioengineering: Filamentous fungi biorefinery*. Elsevier - Health Sciences Division.
- Vandenbergh, L. P. S., Pandey, A., Carvalho, J. C., Letti, L. A. J., Woiciechowski, A. L., Karp, S. G., Thomaz-Soccol, V., Martínez-Burgos, W. J., Penha, R. O., Herrmann, L. W., Rodrigues, A. O., & Soccol, C. R. (2021). Solid-state fermentation technology and innovation for the production of agricultural and animal feed bioproducts. *Systems Microbiology and Biomanufacturing*, 1(2), 142–165. <https://doi.org/10.1007/s43393-020-00015-7>.