

MINIMIZACIÓN DE DISTORSIÓN ARMÓNICA TOTAL EN UN INVERSOR MULTINIVEL APLICANDO MÉTODOS BIOINSPIRADOS: ANÁLISIS COMPARATIVO

Lozoya Ponce Ricardo E.¹, Gómez Díaz Kenia Y.², Portillo Contreras Samuel.³, Flores Rodríguez Eligio⁴, Aguayo Alquicira Jesus⁵, De León Aldaco Susana E.⁶

Tecnológico Nacional de México/Instituto Tecnológico de Chihuahua, Tecnológico Nacional de México/CENIDET, Nacional de México/Instituto Tecnológico Superior de Irapuato

División de Posgrado e Investigación, Departamento de Ingeniería Electrónica

Chihuahua, México, Cuernavaca, México, Irapuato, México

Tel. (52) 614 201 2000, (52) 777 362 7770, (52) 4626067900

ricardo.lp@chihuahua.tecnm.mx¹, d21ce033@cenidet.tecnm.mx², samuel.portillo@uaem.mx³, eligio.fr@irapuato.tecnm.mx⁴, jesus.aa@cenidet.tecnm.mx⁵, susana.da@cenidet.tecnm.mx⁶.

RESUMEN

Este artículo presenta un análisis comparativo de la reducción del contenido armónico total (THD) en un inversor multinivel de 7 niveles con configuración de puente H en cascada, utilizando el algoritmo de optimización basado en enseñanza y aprendizaje (Teaching-Learning-Based Optimization, TLBO). El desempeño del TLBO se contrasta con tres algoritmos metaheurísticos ampliamente utilizados: Algoritmo Genético (GA), Evolución Diferencial (DE) y Optimización por Enjambre de Partículas (PSO). La evaluación se llevó a cabo mediante simulaciones que consideraron métricas como el porcentaje de THD. Los resultados muestran que TLBO ofrece soluciones de alta calidad y es particularmente eficaz para abordar problemas multiobjetivo con múltiples restricciones. Una de sus principales ventajas es que no requiere parámetros de ajuste, a diferencia de los otros algoritmos comparados, lo que facilita su implementación práctica.

Palabras Clave: Algoritmo TLBO, Convertidor de potencia, Electrónica de potencia, Inversor multinivel, Optimización.

ABSTRACT

This paper presents a comparative analysis of total harmonic content (THD) reduction in a 7-level multilevel inverter with cascaded H-bridge configuration using the Teaching-Learning-Based Optimization (TLBO) algorithm. The performance of TLBO is contrasted with three widely used metaheuristic algorithms: Genetic Algorithm (GA), Differential Evolution (DE) and Particle Swarm Optimization (PSO). The evaluation was carried out using simulations that considered metrics such as THD percentage. The results show that TLBO offers high quality solutions and is particularly effective in addressing multi-objective problems with multiple constraints. One of its main advantages is that it does not require tuning parameters, unlike the other compared algorithms, which facilitates its practical implementation.

Keywords: TLBO algorithm, Power converter, Power electronics, Multilevel inverter, Optimization.

1. INTRODUCCIÓN

La optimización abarca una amplia gama de disciplinas, desde la planificación empresarial hasta aplicaciones industriales

complejas. No obstante, los problemas no lineales o de gran escala suelen presentar una alta complejidad computacional. En este contexto, los algoritmos bio-inspirados han cobrado relevancia como herramientas eficaces para resolver problemas de optimización y manejo de datos. Uno de estos métodos es el algoritmo de Enseñanza-Aprendizaje (TLBO), propuesto por el Dr. V. Rao [1], el cual se inspira en la dinámica pedagógica de un aula, donde el profesor guía a los estudiantes hacia un mejor rendimiento. TLBO pertenece a la categoría de algoritmos de inteligencia de enjambre y se caracteriza por ser un método heurístico estocástico basado en población, orientado a la búsqueda de soluciones óptimas en espacios complejos de diseño. El algoritmo TLBO ha ganado popularidad debido a su enfoque original, la ausencia de parámetros ajustables, su rapidez y facilidad de implementación. Estas características lo han convertido en una herramienta ampliamente utilizada en la resolución de diversos problemas de ingeniería [1], [2], [3], [4], [5], [6]. Por otro lado, los inversores multinivel permiten generar señales de corriente alterna (CA) a partir de múltiples niveles de tensión continua (CC). Al incrementar el número de niveles, la forma de onda resultante se aproxima a una señal sinusoidal pura, reduciendo significativamente la distorsión armónica. Esta tecnología permite cumplir con normativas internacionales como IEEE 519 y EN 50160, que establecen un límite de distorsión armónica total (THD) inferior al 8% [7], [8]. En la Figura 1, se muestran los tipos más comunes de inversores y se resalta en color amarillo la ruta seguida para la elección de la topología seleccionada como caso de estudio.




Figura 1. Tipos de inversores multinivel (elaboración propia).

En este estudio se emplea la topología de inversor multinivel tipo puente H en cascada, seleccionada por sus múltiples ventajas frente a otras configuraciones [9]. Entre sus beneficios destacan su menor volumen por el uso reducido de componentes, la generación de tensión en modo común que disminuye el estrés eléctrico, una baja distorsión en la corriente de entrada, y una salida con bajo THD sin requerir filtrado adicional. Además, puede operar a dos frecuencias fundamentales de conmutación. Sin embargo, esta topología también presenta limitaciones, como la necesidad de múltiples fuentes de corriente continua o capacitores individuales por módulo, y la exigencia de un sistema de control más complejo para gestionar adecuadamente estos elementos.

La optimización constituye una herramienta fundamental en diversas áreas, desde el diseño industrial hasta la toma de decisiones empresariales. Sin embargo, muchos problemas de optimización, especialmente aquellos de naturaleza no lineal o de gran escala, presentan un alto grado de complejidad. En este contexto, los algoritmos bio-inspirados han ganado relevancia por su capacidad para abordar eficazmente este tipo de problemas mediante estrategias heurísticas no determinísticas [10]. Entre los algoritmos más representativos se encuentran el algoritmo genético (GA) y el algoritmo de evolución diferencial (DE), ambos ampliamente utilizados desde hace varias décadas. El GA, desarrollado en la década de 1960 e inspirado en la teoría de la evolución de Darwin, se basa en operadores como la selección, cruce y mutación. De manera paralela, surgieron enfoques como la programación evolutiva, que junto con otros métodos forman parte de la computación evolutiva [11]. Estos algoritmos comparten características clave como su naturaleza adaptativa, estructura paralela con múltiples agentes, y la capacidad de incorporar retroalimentación del entorno para guiar la búsqueda hacia soluciones óptimas.

En el presente estudio, el algoritmo TLBO se analiza como una alternativa moderna para la minimización de la distorsión armónica total (THD) en inversores multinivel. Con el fin de evaluar su desempeño y robustez, se realiza una comparación con algoritmos de referencia consolidados, como GA y DE, que cuentan con amplio respaldo en la literatura y han demostrado efectividad en aplicaciones similares. Esta estrategia comparativa permite generar indicadores relevantes y contextualizar los resultados obtenidos con TLBO dentro de un marco de validación riguroso.

2. MÉTODOS

Para el desarrollo de este estudio, se realizó una selección deliberada de la topología del inversor multinivel, considerando criterios técnicos alineados con el objetivo de minimizar la distorsión armónica total (THD). En primer lugar, se optó por un inversor multinivel con fuentes de corriente continua (CD) separadas, implementado mediante una topología de puente H en cascada con fuentes iguales. Esta configuración proporciona mayor flexibilidad y control sobre el voltaje de salida, lo que

resulta ventajoso para estrategias de modulación avanzadas. En segundo lugar, se analizó la conveniencia de emplear un inversor monofásico o trifásico. Aunque los inversores trifásicos permiten la eliminación natural del tercer armónico y, por ende, una reducción significativa del THD, se decidió trabajar con un inversor monofásico, ya que representa un escenario más desafiante al presentar mayores niveles de distorsión armónica. Esta elección permite una evaluación más exigente del desempeño de los algoritmos de optimización propuestos.

2.1. Algoritmo de Optimización Basado en Enseñanza-Aprendizaje (TLBO)

El algoritmo de optimización basado en enseñanza-aprendizaje (*Teaching-Learning-Based Optimization*, TLBO), propuesto por Rao en 2011, se inspira en la dinámica del proceso educativo entre un profesor y sus estudiantes. Clasificado dentro de los métodos de inteligencia de enjambre, TLBO se ha consolidado como una técnica efectiva y ampliamente utilizada en problemas de ingeniería, destacando por su simplicidad, eficiencia y la ventaja de no requerir la configuración de parámetros específicos por parte del usuario [12]. TLBO opera sobre una población de soluciones, análoga a un grupo de estudiantes con distintos niveles de desempeño, y mejora iterativamente la calidad de dichas soluciones a través de dos fases principales: la fase del profesor y la fase del alumno. En la fase del profesor, cada solución es actualizada en función de la mejor solución actual (el “profesor”), lo que simula un proceso de aprendizaje guiado. En la fase del alumno, las soluciones mejoran mediante la interacción entre pares aleatorios, promoviendo el aprendizaje colaborativo [13].

El proceso iterativo de TLBO se resume en la generación de nuevas soluciones y su evaluación con base en una función objetivo. Si una nueva solución supera a la mejor solución actual y se cumplen los criterios de terminación, esta se actualiza. Además, se incorporan comparaciones entre soluciones aleatorias para fortalecer la exploración del espacio de búsqueda. El algoritmo TLBO se estructura en tres etapas principales: inicialización, fase del profesor y fase de aprendizaje, las cuales se desarrollan iterativamente hasta cumplir un criterio de terminación previamente definido.

La Figura 2 muestra el diagrama de flujo que describe este procedimiento iterativo, el cual continúa hasta alcanzar los criterios de convergencia definidos, momento en el cual se reporta la mejor solución encontrada.

Inicialización: El usuario establece los parámetros iniciales del algoritmo, que incluyen el tamaño de la población (número de soluciones candidatas), el número de variables a optimizar y el criterio de parada, comúnmente definido como el número máximo de iteraciones.

Fase del profesor: En esta etapa, cada solución (alumno) busca mejorar su desempeño a partir de la influencia de la mejor solución actual (profesor). Se considera una población de “n”

soluciones y “m” variables de diseño. El promedio de desempeño por variable se calcula y se emplea para ajustar las soluciones, promoviendo que todas converjan hacia el rendimiento del mejor individuo de la población, considerado como el “profesor”.

Fase de aprendizaje entre alumnos: Aquí, las soluciones se mejoran mediante la interacción entre pares seleccionados aleatoriamente. Cada alumno actualiza su posición en el espacio de búsqueda considerando la diferencia de desempeño respecto a otro compañero, ajustada por un factor de aprendizaje. Este mecanismo fomenta la diversidad y permite explorar nuevas regiones del espacio de soluciones.

En los siguientes nueve pasos el proceso iterativo continúa hasta que se cumple el criterio de terminación definido en la fase de inicialización. A partir de estas etapas, la ejecución del algoritmo TLBO puede describirse en siguientes nueve pasos operativos consecutivos:

- 1) Formulación de la función objetivo o función de aptitud.
- 2) Inicialización de los parámetros de optimización y de los límites de las variables.
- 3) Generación de una población aleatoria. La población se expresa en la ecuación 1:

$$Población = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1D} \\ x_{21} & x_{22} & \dots & x_{2D} \\ \dots & \dots & \dots & \dots \\ x_{P_n,1} & x_{P_n,2} & \dots & x_{P_n,D} \end{bmatrix} \quad (1)$$

- 4) Fase del profesor: La media de la variable particular puede calcularse como la ecuación 2.

$$M_{*,D} = [m_1, m_2, \dots, m_D] \quad (2)$$

- 5) La mejor solución será considerada como maestro para esa iteración como en la ecuación (3):

$$X_{teacher} = X_{(f(X)=\min)} \quad (3)$$

- 6) Ordenar la nota de cada variable de cada alumno y se calcula el nuevo destete. La diferencia entre dos medias se puede calcular con ecuación (4), TF puede ser considerado como 1 o 2.

$$Difference_{*,D} = r(M_{new,D} - T_F \times M_{*,D}) \quad (4)$$

- 7) Actualizar los valores añadiendo la diferencia a la solución anterior, como se observa en la ecuación (5).

$$X_{new,D} = X_{old,D} + Difference_{*,D} \quad (5)$$

- 8) En esta segunda fase del algoritmo TLBO, conocida como fase de aprendizaje, el proceso de mejora del rendimiento se enriquece con la transferencia de conocimientos entre los propios alumnos (soluciones). Las ecuaciones matemáticas que rigen esta fase de aprendizaje colaborativo se describen en la ecuación (6):

$$\begin{cases} X_{new,i} = X_{old,i} + r_i(X_i - X_j) \\ X_{new,i} = X_{old,i} + r_i(X_i + X_j) \end{cases} \quad (6)$$

- 9) El proceso finalizará sólo si se alcanza la generación máxima, de lo contrario se repetirá todo el proceso.




Figura 2. Diagrama de flujo del algoritmo (elaboración propia).

3. RESULTADOS

3.1. Análisis comparativo de los parámetros de control en algoritmos bio-inspirados

El algoritmo TLBO se distingue por no requerir parámetros de control específicos, utilizando únicamente parámetros de inicialización comunes a todos los algoritmos, como el tamaño de población, número máximo de iteraciones y evaluaciones de la función. En contraste, algoritmos como GA, DE y especialmente PSO requieren parámetros de control adicionales que condicionan su desempeño. La Tabla 1 muestra los parámetros utilizados en este estudio.

Tabla 1. Comparación de los parámetros de cada uno de los algoritmos

Algoritmo	TLBO	GA	DE	PSO
Población	20	20	20	20
Iteraciones	50	50	50	50
# de Eval. de Función	50	50	50	50

Parámetros de Control	No tiene	CR	MR	CR	F	C1, C2	W _{max}	W _{min}
Valor	-	0.8	0.2	1	0.8	2	0.9	0.4

Aunque en este estudio se emplearon valores estándar extraídos de la literatura para una comparación homogénea, la optimización en problemas nuevos demanda la adaptación y ajuste de dichos parámetros para obtener resultados óptimos. Se observó que, aunque TLBO presenta un mayor tiempo de ejecución al cumplir todas las iteraciones programadas, alcanza soluciones cercanas al mínimo desde etapas tempranas del proceso [14].

De acuerdo con la norma IEEE-519, se deben de evaluar por lo menos 50 componentes armónicas para calcular el porcentaje de Distorsión Armónica Total de Tensión (THDV). Este cálculo realiza con la ecuación (7), el cual tiene la finalidad de determinar la calidad de la señal de tensión en la salida de un inversor.

$$\%THD = \left(\frac{\sqrt{\sum_{n=1,3,5,\dots}^{50} V_n^2}}{V_1} \right) \times 100 \quad (7)$$

donde n se define como el orden del armónico impar (1,3,5,7, ... 49), V_1 es el valor del primer armónico, es decir el voltaje fundamental y V_n^2 se refiere a $\left(\frac{4V_{CD}}{n\pi} [\cos(n\theta_1) + \cos(n\theta_2) + \dots \cos(n\theta_s)] \right)^2$, cumpliendo con las restricciones siguientes mostradas en la ecuación (8).

$$\theta_1 < \theta_2 < \dots \theta_s < \frac{\pi}{2} \quad (8)$$

La función objetivo (FO) se define en función del índice de modulación (IM) y el porcentaje de THD, orientada a optimizar los ángulos de conmutación dentro de un rango de IM de 0.44 a 1.16. El término relacionado con el IM corresponde al valor absoluto del error entre el armónico fundamental deseado y el obtenido, asegurando así el ajuste preciso del primer armónico, como se expresa en la ecuación (9).

$$FO = |V_1^* - V_1| + \%TH \quad (9)$$

Mediante la función objetivo y el software Matlab, se calcularon los ángulos de conmutación para un inversor con IGBT APT30GF60BN (30 A, 600 V), fuentes de CC de 60 V, resistencias de base de 20 Ω , potencia 1kW y frecuencia de 60 Hz. La Tabla 2 compara el porcentaje de THD calculado y simulado para los cuatro algoritmos analizados, considerando hasta el armónico 49. Se observa una ligera variación decimal entre ambos métodos, lo que confirma la validez y precisión de los ángulos de disparo obtenidos mediante simulación.

Tabla 2. Comparación del porcentaje de THD mediante los cálculos teóricos y simulados.

Algoritmo	%THD Teórico	%THD Simulación
TLBO	10.4660	10.467
GA	10.6907	10.692
DE	10.7819	10.784
PSO	10.4705	10.471

La Figura 3 presenta el esquema detallado del inversor multinivel monofásico de 7 niveles con configuración puente H en cascada.




Figura 3. Esquemático del inversor multinivel de 7 niveles puente H en cascada (elaboración propia).

En la Tabla 3 se pueden observar los valores de simulación utilizados en este trabajo [15].

Tabla 3. Parámetros de simulación para el primer puente H

NOMBRE	V1 [V]	V2 [V]	TD [ms]	TR [ns]	TF [ns]	PW [ms]	PER [ms]
V6 (pulso)	0	15	14.66-Ang1	10	10	10	16.66
V7 (pulso)	0	15	8.33-Ang1	10	10	10	16.66
V9 (pulso)	0	15	6.33-Ang1	10	10	10	16.66
V10(pulso)	0	15	Ang1	10	10	10	16.66

En la Figura 4 se presenta la forma de onda de la tensión de salida del inversor multinivel utilizando los ángulos de conmutación obtenidos a través del algoritmo TLBO. En la Figura 5, se muestra la Transformada Rápida de Fourier (FFT) para analizar los armónicos generados con estos ángulos y, finalmente, compararlos con los armónicos calculados del algoritmo TLBO.




Figura 4. Señal de la tensión de salida con los ángulos del algoritmo TLBO (elaboración propia).






Figura 5. FFT con los ángulos de conmutación obtenidos con el algoritmo TLBO (elaboración propia).


En la Figura 6 se muestran las FFT de los algoritmos que se eligieron como punto de comparación, siendo alguno de los más populares para su aplicación en inversores multinivel, también se añade el cálculo de la THD que se presentan mediante el cálculo de los ángulos por parte de los algoritmos GA, DE y PSO respectivamente.



a) FFT con los ángulos de conmutación con el algoritmo GA



b) FFT con los ángulos de conmutación con el algoritmo DE



c) FFT con los ángulos de conmutación con el algoritmo PSO

Figura 6. FFT con los ángulos de conmutación de cada uno de los algoritmos (elaboración propia).

4. DISCUSIONES

En esta sección se presenta una comparación gráfica detallada del comportamiento de los cuatro algoritmos analizados en relación con la optimización del índice de distorsión armónica total (THD), y el contenido armónico de la señal de salida. La

información visual proporcionada permite evaluar de manera clara y precisa el desempeño de cada algoritmo bajo diferentes condiciones de operación. La Figura 7 muestra la variación de los ángulos de disparo obtenidos por los cuatro algoritmos en función del índice de modulación. Se observa que el ángulo 3 varía entre 35° y 89.99° , el ángulo 2 entre 20° y 85° , y el ángulo 1 entre 5° y 25° . Este comportamiento es coherente con la relación esperada entre el índice de modulación y los ángulos de disparo: a valores bajos del índice de modulación, los ángulos de disparo tienden a ser mayores, ya que el inversor debe generar niveles de voltaje más bajos, lo cual requiere un mayor tiempo de conducción para los interruptores. Por el contrario, cuando el índice de modulación es alto, los ángulos de disparo disminuyen, debido a la necesidad de producir voltajes más elevados con un menor tiempo de conducción. Cabe destacar que el rango de barrido del índice de modulación se encuentra limitado entre 0.44 y 1.16, conforme a las restricciones impuestas en la función objetivo y con la finalidad de conocer el comportamiento del inversor y la THD. Esta delimitación garantiza que el inversor opere dentro de márgenes seguros y eficientes, evitando condiciones de funcionamiento que puedan comprometer su estabilidad o rendimiento.




Figura 7. Porcentaje de THD con respecto al índice de modulación que se desea tener (elaboración propia).

La Figura 8 muestra una comparación detallada del contenido armónico de la señal de salida generada por cada algoritmo, considerando el intervalo comprendido entre el tercer armónico y el armónico 49. Esta representación, con una escala ampliada, facilita la observación del comportamiento de los armónicos superiores, cuya visualización se ve dificultada por la predominancia de la componente fundamental. Los resultados evidencian que los algoritmos TLBO y PSO presentan una menor amplitud en la mayoría de los armónicos analizados en comparación con los algoritmos GA y DE. Esta tendencia sugiere que TLBO y PSO lograron una optimización más eficaz de la función objetivo, al reducir significativamente la presencia de armónicos no deseados en la señal de salida. En consecuencia, se observa una mejora sustancial en la calidad de la forma de onda obtenida. En el contexto de los inversores multinivel, el cálculo en línea de los ángulos de conmutación constituye un aspecto crítico para el desempeño del sistema. Estos ángulos deben determinarse dinámicamente durante la operación del inversor conectado a la red, con el fin de maximizar su eficiencia

y garantizar un control preciso de la forma de onda de salida. Este proceso de cálculo representa un desafío computacional considerable, ya que debe ejecutarse en tiempo real para asegurar la estabilidad y continuidad del funcionamiento del inversor. Por tanto, la selección de algoritmos de optimización que ofrezcan una adecuada relación entre precisión y velocidad de convergencia es fundamental para aplicaciones en entornos dinámicos o de respuesta rápida.




Figura 8. Porcentaje de THD con respecto al índice de modulación que se desea tener (elaboración propia).

5. CONCLUSIONES

Los inversores multinivel tienen una gran gama de aplicaciones. Este trabajo no se enfocó en explorar una aplicación específica, el presente estudio tuvo como objetivo analizar el desempeño del algoritmo Teaching-Learning-Based Optimization (TLBO) en la optimización del porcentaje de distorsión armónica total (THD, por sus siglas en inglés) en un inversor multinivel de siete niveles.

Este objetivo se alcanzó satisfactoriamente mediante la realización de simulaciones y un análisis exhaustivo de los resultados obtenidos. Los hallazgos confirman que el TLBO es un método metaheurístico eficaz para abordar problemas de optimización, especialmente aquellos que involucran múltiples objetivos y restricciones. Una de sus principales ventajas radica en su simplicidad operativa, al no requerir el ajuste de parámetros complejos por parte del usuario, lo que facilita su implementación en diversas aplicaciones. El análisis comparativo reveló que el TLBO ofrece un rendimiento notable en términos de calidad de solución, incluso sin necesidad de sintonización de parámetros. Su estructura simple y su capacidad de ser implementado en tiempo real lo posicionan como una alternativa viable para aplicaciones que requieren soluciones rápidas y eficientes.

6. REFERENCIAS

- [1] R. V. Rao, V. J. Savsani, and D. P. Vakharia, "Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problems," *Comput. Des.*, vol. 43, no. 3, pp. 303–315, 2011.
- [2] K. Y. Gómez Díaz, S. E. De León Aldaco, J. Aguayo Alquicira, M. Ponce-Silva, and V. H. Olivares Peregrino, "Teaching-learning-based optimization algorithm applied in electronic engineering: A survey," *Electronics*, vol. 11, no. 21, p. 3451, 2022.
- [3] J. Nayak, B. Naik, G. T. Chandrasekhar, and H. S. Behera, "A survey on teaching-learning-based optimization algorithm: short journey from 2011 to 2017," in *Computational Intelligence in Data Mining: Proceedings of the International Conference on CIDM 2017*, Springer, 2019, pp. 739–758.
- [4] E. A. Hamed, I. K. Jebur, M. A. Hasan, R. A. Salman, and H. A. Jawdhari, "An improved teaching-learning-based optimization: Briefly survey," *Turkish J. Comput. Math. Educ.*, vol. 12, no. 11, pp. 2315–2319, 2021.
- [5] R. Xue and Z. Wu, "A survey of application and classification on teaching-learning-based optimization algorithm," *IEEE Access*, vol. 8, pp. 1062–1079, 2019.
- [6] O. Sánchez-Vargas, S. Estefany De León-Aldaco, J. Aguayo-Alquicira, and A. Rafael López-Núñez, "Evolutionary Metaheuristic Methods Applied to Minimize the THD in Inverters: A Systematic Review," *Eur. J. Electr. Eng. Int. Génie Electr.*, vol. 23, no. 3, 2021.
- [7] C. K. Duffey and R. P. Stratford, "Update of harmonic standard IEEE-519: IEEE recommended practices and requirements for harmonic control in electric power systems," *IEEE Trans. Ind. Appl.*, vol. 25, no. 6, pp. 1025–1034, 1989, doi: 10.1109/28.44238.
- [8] P. Q. A. Guide, "Voltage disturbances," *Stand. EN*, vol. 50160, 2004.
- [9] A. K. R and L. P. Suresh, "A brief review on multi level inverter topologies," in *2016 International Conference on Circuit, Power and Computing Technologies (ICCPCT)*, 2016, pp. 1–6. doi: 10.1109/ICCPCT.2016.7530373.
- [10] S. Ürgün, H. Yiğit, and S. Mirjalili, "Investigation of recent metaheuristics based selective harmonic elimination problem for different levels of multilevel inverters," *Electronics*, vol. 12, no. 4, p. 1058, 2023.
- [11] S. Katoch, S. S. Chauhan, and V. Kumar, "A review on genetic algorithm: past, present, and future," *Multimed. Tools Appl.*, vol. 80, pp. 8091–8126, 2021.
- [12] F. Zou, D. Chen, and Q. Xu, "A survey of teaching-learning-based optimization," *Neurocomputing*, vol. 335, pp. 366–383, 2019.
- [13] R. V. Rao and R. V. Rao, *Teaching-learning-based optimization algorithm*. Springer, 2016.
- [14] M. A. Memon, S. Mekhilef, M. Mubin, and M. Aamir, "Selective harmonic elimination in inverters using bio-inspired intelligent algorithms for renewable energy conversion applications: A review," *Renew. Sustain. Energy Rev.*, vol. 82, pp. 2235–2253, 2018.

- [15] K. Y. Gómez Díaz, S. E. de León Aldaco, J. Aguayo Alquicira, and L. G. Vela Valdés, "THD minimization in a seven-level multilevel inverter using the TLBO algorithm," *Eng*, vol. 4, no. 3, pp. 1761–1786, 2023.