

ORIGINAL

Advanced Mechanical Gear Design Optimization through Multivariate Statistical Modeling: Strength Analysis and Wear Mitigation Strategies

Optimización Avanzada del Diseño de Engranajes Mecánicos mediante Modelado Estadístico Multivariable: Análisis de Resistencia y Estrategias de Mitigación del Desgaste

Rodrigo Rigoberto Moreno Pallares¹  , Juan Carlos Quinchuela Paucar¹  , Patricia Pilar Moyota Amaguaya¹  , Luis Fernando Buenaño Moyano¹  

¹Escuela Superior Politécnica de Chimborazo (ESPOCH), Riobamba, Ecuador.

Citar como: Moreno Pallares RR, Quinchuela Paucar JC, Moyota Amaguaya PP, Buenaño Moyano LF. Advanced Mechanical Gear Design Optimization through Multivariate Statistical Modeling: Strength Analysis and Wear Mitigation Strategies. Salud, Ciencia y Tecnología. 2025; 5:1752. <https://doi.org/10.56294/saludcyt20251752>

Enviado: 15-11-2024

Revisado: 25-02-2025

Aceptado: 06-06-2025

Publicado: 07-06-2025

Editor: Prof. Dr. William Castillo-González 

Autor de correspondencia: Rodrigo Rigoberto Moreno Pallares 

ABSTRACT

Introduction: mechanical gears are essential components in power transmission in industrial, automotive and aerospace systems.

Objective: advanced optimization of mechanical gear design is explored using multivariate statistical modeling, with a focus on structural strength and wear mitigation.

Method: the NSGA-II algorithm was applied to identify optimal solutions on the Pareto front, balancing wear minimization and mechanical strength maximization.

Results: the results indicate that a modulus close to 5,0 and a pressure angle of 24°-25° optimize durability and gear efficiency. In addition, linear regression showed a high predictive ability ($R^2=0,882$ for wear and $R^2=0,963$ for strength), although limited to a single-objective approach.

Conclusion: it is concluded that the combination of NSGA-II with statistical models and numerical simulation can improve the accuracy and applicability of solutions in industrial environments.

Keywords: Wear; Modeling; Multivariate; Optimization; Strength.

RESUMEN

Introducción: los engranajes mecánicos son componentes esenciales en la transmisión de potencia en sistemas industriales, automotrices y aeroespaciales.

Objetivo: se explora la optimización avanzada del diseño de engranajes mecánicos mediante modelado estadístico multivariable, con un enfoque en la resistencia estructural y la mitigación del desgaste.

Method: se aplicó el algoritmo NSGA-II para identificar soluciones óptimas en el frente de Pareto, equilibrando la minimización del desgaste y la maximización de la resistencia mecánica.

Resultados: los resultados indican que un módulo cercano a 5,0 y un ángulo de presión de 24°-25° optimizan la durabilidad y la eficiencia del engranaje. Además, la regresión lineal mostró una alta capacidad predictiva ($R^2=0,882$ para el desgaste y $R^2=0,963$ para la resistencia), aunque limitada a un enfoque monoobjetivo.

Conclusión: se concluye que la combinación de NSGA-II con modelos estadísticos y simulación numérica puede mejorar la precisión y aplicabilidad de las soluciones en entornos industriales.

Palabras claves: Desgaste; Modelado; Multivariado; Optimización; Resistencia.

INTRODUCCIÓN

Los engranajes mecánicos son componentes esenciales en la transmisión de potencia en sistemas industriales, automotrices y aeroespaciales. Su diseño óptimo implica equilibrar resistencia mecánica, durabilidad y eficiencia, mientras se minimizan fallas como el desgaste, la fatiga y la fractura. En los últimos años, el uso de modelado estadístico ha emergido como una herramienta poderosa para optimizar estos parámetros, integrando análisis numéricos, simulaciones por elementos finitos (FEA, por sus siglas en inglés) y enfoques experimentales para predecir y mejorar el comportamiento de los engranajes bajo carga.⁽¹⁾

Evolución del diseño de engranajes

Inicialmente, los engranajes se fabricaban mediante técnicas de mecanizado tradicionales, lo que limitaba su eficiencia y rendimiento. El advenimiento del diseño asistido por ordenador (CAD) y de los métodos computacionales a finales del siglo XX marcó un punto de inflexión importante. Los ingenieros comenzaron a emplear técnicas avanzadas de modelado para analizar la resistencia y la salud dinámica del engranaje, incorporando métodos estadísticos para optimizar parámetros de diseño como la relación de transmisión, el par y las propiedades del material.⁽²⁾

La integración de algoritmos metaheurísticos amplió aún más el espacio de diseño, permitiendo la exploración de geometrías y topologías complejas que superan los enfoques tradicionales de optimización.⁽³⁾

En particular, este campo se ha enfrentado a desafíos, incluida la detección eficaz de fallas de engranajes y la fiabilidad de los modelos estadísticos para predecir el rendimiento bajo condiciones variables.⁽⁴⁾ Las preocupaciones relativas a la adecuación de los factores de fiabilidad existentes y las demandas computacionales de los algoritmos de optimización también presentan obstáculos.⁽⁵⁾ Sin embargo, se espera que los avances en la ciencia de materiales y las tecnologías de fabricación inteligente reformen el futuro del diseño de engranajes, haciendo hincapié en la sostenibilidad y las capacidades predictivas mejoradas.

La optimización del diseño de engranajes mecánicos tiene una rica historia arraigada en la evolución de las prácticas de ingeniería y los avances tecnológicos. Los primeros diseños de engranajes se centraron principalmente en la funcionalidad, pero con el tiempo, el énfasis cambió hacia la mejora de la eficiencia, la reducción del ruido y el aumento de la fiabilidad a través de enfoques sistemáticos.⁽⁶⁾

Las metodologías de ingeniería asistida por ordenador han sido fundamental para revolucionar el diseño de engranajes. Al incorporar análisis de fiabilidad estadística, los diseñadores de engranajes pueden ahora anticipar y mitigar posibles modos de falla, lo que conduce a una mayor durabilidad y eficiencia operativa.⁽⁷⁾

Los recientes avances en algoritmos de optimización metaheurística, como los algoritmos genéticos y el recocido simulado, han ampliado aún más el espacio de diseño, permitiendo la exploración de complejos y la identificación de soluciones innovadoras que superen los enfoques tradicionales del diseño.⁽⁸⁾

A pesar de estos avances, la optimización del diseño de engranajes mecánicos se enfrenta con desafíos continuos, incluyendo la detección precisa de fallas en los engranajes, la fiabilidad de los modelos estadísticos para predecir el rendimiento bajo condiciones variables, y las exigencias computacionales de los algoritmos de optimización.⁽⁹⁾

El papel de los métodos estadísticos

La integración de los métodos estadísticos en el diseño de las máquinas ha sido fundamental. En la década de 2010, las investigaciones comenzaron a centrarse en la aplicación del análisis de fiabilidad estadística y el modelado predictivo para evaluar el rendimiento de los engranajes bajo condiciones operativas variables. Este enfoque proactivo permitió a los ingenieros predecir los modos de falla y optimizar los sistemas de engranajes para mejorar la durabilidad y la eficiencia.⁽¹⁰⁾

Al utilizar técnicas estadísticas avanzadas, los diseñadores podían analizar grandes cantidades de datos para identificar factores críticos que afectaban el rendimiento y la fiabilidad de las ruedas, lo que conducía a diseños más robustos y fiables.⁽¹¹⁾

Avances en técnicas de optimización

A medida que el campo progresaba, surgieron varios algoritmos de optimización, incluidos los Algoritmos Genéticos (GA), el Recocido Simulado y la Optimización de Colonias de Hormigas, estos métodos aprovecharon los principios de la selección natural y la biología evolutiva para descubrir diseños de engranajes óptimos o casi óptimos en medio de parámetros complejos.⁽¹²⁾

La flexibilidad y el poder computacional de estos algoritmos permitieron explorar topologías y geometrías innovadoras de engranajes, dando lugar a soluciones que superaron los diseños tradicionales. El enfoque en la mejora de la eficiencia del engranaje dio lugar a innovaciones como la implementación de engranajes cónicos rectos, que demostraron mejoras significativas en el rendimiento operativo y niveles de ruido reducidos en aplicaciones industriales.⁽¹³⁾

En el ámbito de la ingeniería mecánica, la durabilidad y eficiencia de los engranajes son factores cruciales que definen el éxito de cualquier aplicación. A medida que la tecnología avanza, la necesidad de sistemas más

eficientes y duraderos se hace cada vez más aparente.⁽¹⁴⁾

NSGA-II: Un Algoritmo de Optimización Multiobjetivo

El algoritmo NSGA-II es una de las metodologías más utilizadas para la optimización multiobjetivo, gracias a su capacidad para encontrar soluciones óptimas en problemas con objetivos en conflicto. A diferencia de los métodos tradicionales de optimización, NSGA-II utiliza un enfoque basado en evolución genética, donde una población de soluciones potenciales es evaluada y mejorada a lo largo de múltiples generaciones.⁽¹⁵⁾

La eficiencia del algoritmo NSGA-II radica en su mecanismo de clasificación por dominancia no estricta, que permite identificar soluciones en el frente de Pareto, es decir, aquellas que no pueden ser mejoradas en un objetivo sin empeorar otro.⁽¹⁶⁾ Este algoritmo ha sido ampliamente utilizado en problemas de diseño de ingeniería, incluyendo la optimización estructural y mecánica de engranajes, donde se busca minimizar el desgaste y maximizar la resistencia.⁽¹⁷⁾

Uno de los principales desafíos en la implementación de NSGA-II es la correcta formulación de las funciones objetivo y restricciones, ya que valores no factibles pueden generar soluciones inviables con resultados extremos, como tasas de desgaste infinitas o resistencias negativas.⁽¹⁸⁾

Para garantizar su efectividad, se recomienda utilizar técnicas de normalización y penalización de soluciones no factibles, evitando que el algoritmo explore regiones del espacio de búsqueda sin sentido físico. Además, el desempeño de NSGA-II puede mejorarse mediante la hibridación con otros métodos, como la Optimización por Enjambre de Partículas (PSO) o el Recocido Simulado (SA), lo que permite una exploración más eficiente del espacio de soluciones.⁽¹⁹⁾

En la optimización del diseño de engranajes mecánicos, NSGA-II ha demostrado ser efectivo para balancear múltiples criterios de desempeño, incluyendo la eficiencia mecánica, la vida útil y el consumo energético,⁽²⁰⁾ estudios recientes han aplicado este algoritmo en el diseño de cajas de engranajes y trenes de transmisión, logrando reducir el desgaste en más de un 15 % sin comprometer la capacidad de carga.

Para obtener resultados realistas, es esencial combinar NSGA-II con modelos predictivos sólidos, como los obtenidos mediante regresión estadística y análisis numérico por Elementos Finitos (FEM), que pueden obtener soluciones más confiables y aplicables en entornos industriales.⁽²¹⁾

Este artículo se centró en el mejoramiento de la durabilidad y eficiencia de los engranajes mecánicos a través de la identificación de parámetros de diseño clave. Se explorarán técnicas y metodologías para analizar y optimizar estos parámetros, con el objetivo de reducir el desgaste, aumentar la vida útil y mejorar el rendimiento general de los sistemas de engranajes.

MÉTODO

Modelado Estadístico en el Diseño de Engranajes

El modelado estadístico se realizó utilizando funciones objetivo como las tensiones de contacto, para determinar las tensiones por flexión y la temperatura de operación. De manera similar, propusieron un método paramétrico basado en elementos finitos para optimizar árboles de transmisión en reductores de velocidad con engranajes cilíndricos. Su modelo incorporó una base de datos parametrizada y análisis estadístico para evaluar resistencia a la fatiga y rigidez.

Análisis de Resistencia

Se usó la simulación numérica para evaluar la propagación de fisuras en engranajes bajo cargas cíclicas, utilizando modelos estadísticos para correlacionar parámetros como el tamaño de la fisura y la distribución de tensiones con la vida útil del componente, así mismo se empleó la síntesis y optimización de trenes de engranajes planetarios, aplicando métodos estadísticos para seleccionar configuraciones que maximicen el rendimiento y la resistencia.

Modelado analítico

Se usó el modelado para derivar ecuaciones diferenciales ordinarias, que luego pueden resolverse para predecir diversos resultados tales como niveles de vibración y aplicaciones de fuerza, este método permitió un análisis no propietario con relativamente pocas entradas, por lo que es accesible para los diseñadores para comprender el comportamiento de las marchas en diferentes condiciones de funcionamiento la cual se detalla a continuación:

Regresión Lineal Múltiple

La fórmula para la regresión lineal múltiple fue

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon$$

Donde:

y es la variable dependiente.

$x_1, x_2, \dots, x_n$ son las variables independientes.

β_0 es el intercepto.

$\beta_1, \beta_2, \dots, \beta_n$ son los coeficientes de las variables independientes.

ϵ es el error aleatorio.

La regresión lineal múltiple es un método para modelar la relación entre una variable dependiente y una o más variables independientes. Se utiliza para predecir o explicar la variabilidad de una variable en función de otras variables.

Formulación Matemática de NSGA-II

La optimización multiobjetivo con funciones objetivo:

$$\min_{x \in X} F(x) = [f_1(x), f_2(x), \dots, f_m(x)]$$

donde x representa un conjunto de variables de decisión, y cada función $f_i(x)$ es una función objetivo que se busca minimizar o maximizar.

Aplicación de Algoritmo NSGA-II

NSGA-II sigue un proceso basado en evolución genética con los siguientes pasos:

Generación de la Población Inicial: Se creó una población de N individuos aleatoriamente.

Clasificación por Dominancia de Pareto: Se organizó la población en diferentes niveles de dominancia.

Cálculo de Distancia de Multitud: Se evaluó la diversidad entre soluciones usando la métrica de “crowding distance”.

Selección, Cruce y Mutación: Se aplicaron operadores genéticos para generar nuevas soluciones: Selección por torneo binario basada en dominancia de Pareto y distancia de multitud.

Cruce de variables de decisión (normalmente con SBX - Simulated Binary Crossover).

Mutación gaussiana o polinómica para explorar nuevas regiones del espacio de búsqueda.

Actualización de la Población: Se combinó la población actual y la nueva generación, y se seleccionan las mejores soluciones.

Iteración hasta la Convergencia: Se repitieron los pasos hasta alcanzar el criterio de parada (número de generaciones o convergencia del frente de Pareto).

Condiciones de Aplicación de NSGA-II

Para que NSGA-II funcione de manera efectiva, se cumplieron ciertas condiciones en su implementación:

Definición de las Funciones Objetivo

Las funciones objetivo fueron continuas y diferenciables, aunque NSGA-II puede manejar problemas con discontinuidades.

En problemas de engranajes, los objetivos típicos fueron:

- Minimizar la tasa de desgaste $f_1(x)$
- Maximizar la resistencia estructural $f_2(x)$

Restricciones del Problema

El espacio de búsqueda se definió dentro de límites físicos y realistas:

$$x_i^{\min} \leq x_i \leq x_i^{\max}, \quad "i = 1, 2, \dots, n$$

En engranajes mecánicos:

- x_1 = Módulo ($1 \leq x_1 \leq 10$)
- x_2 = Ángulo de Presión ($14^\circ \leq x_2 \leq 25^\circ$)
- x_3 = Material (variable categórica que afecta resistencia y desgaste)

Dominancia de Pareto

Una solución X_1 domina a otra solución X_2 si y solo si:

$$\begin{aligned} & \forall i \in \{1, 2, \dots, n\}, f_i(x_1) \leq f_i(x_2), \text{ y} \\ & \exists j \in \{1, 2, \dots, n\}, f_j(x_1) < f_j(x_2) \end{aligned}$$

Es decir, una solución domina a otra si es mejor en al menos un objetivo y no peor en los demás.

Datos utilizados

El conjunto de datos utilizado fue una colección de observaciones relacionadas con el desgaste de engranajes mecánicos. Descripción de cada columna en el conjunto de datos:

Modulo: Este campo represento el módulo del engranaje, que es una medida de la tensión en la que se encuentra el engranaje y está relacionada directamente con la fuerza de tracción.

Angulo Presión: Este campo indico el ángulo de presión, que es la fuerza de fricción aplicada sobre el engranaje y puede afectar el desgaste.

Lubricante: Este campo es una variable categórica que indica el tipo de lubricante utilizado. Los lubricantes listados son “Aceite mineral”, “Aceite sintético” y “Grasa EP”. El tipo de lubricante puede tener un impacto significativo en el desgaste y la vida útil del engranaje.

Tasa Desgaste: Esta fue la variable dependiente, que mide la tasa de desgaste del engranaje. Los valores son medidos en unidad de medida (por ejemplo, $\mu\text{m/h}$) y reflejan la cantidad de material perdida por hora.

RESULTADOS

Los resultados obtenidos con NSGA-II muestran un conjunto de soluciones en el frente de Pareto, lo que significa que representan los mejores compromisos posibles entre la minimización del desgaste y la maximización de la resistencia estructural de los engranajes. En general, se observa en la Figura 1 que las configuraciones con módulos más altos ($\geq 4,5$) y ángulos de presión cercanos a 25° tienden a presentar mayor resistencia mecánica (hasta 125.000 unidades) y menores tasas de desgaste.

Figura 1. Resultados de Optimización multiobjetivo NSGA				
Resultados de la Optimización Multiobjetivo (NSGA-II)				
Módulo: 5,000;	Ángulo de Presión: 25,000;	Tasa de Desgaste: -1,102;	Resistencia: 125,000	
Módulo: 4,002;	Ángulo de Presión: 20,078;	Tasa de Desgaste: -2,135;	Resistencia: 80,354	
Módulo: 4,006;	Ángulo de Presión: 21,055;	Tasa de Desgaste: -2,080;	Resistencia: 84,358	
Módulo: 4,000;	Ángulo de Presión: 24,406;	Tasa de Desgaste: -1,902;	Resistencia: 97,619	
Módulo: 4,001;	Ángulo de Presión: 23,153;	Tasa de Desgaste: -1,969;	Resistencia: 92,639	
Módulo: 4,032;	Ángulo de Presión: 25,000;	Tasa de Desgaste: -1,845;	Resistencia: 100,809	
Módulo: 4,288;	Ángulo de Presión: 25,000;	Tasa de Desgaste: -1,649;	Resistencia: 107,200	
Módulo: 5,000;	Ángulo de Presión: 25,000;	Tasa de Desgaste: -1,102;	Resistencia: 125,000	

Sin embargo, valores más bajos del módulo y del ángulo de presión generan mayores tasas de desgaste, lo que indica que estos parámetros juegan un papel clave en la durabilidad de los engranajes. La tasa de desgaste es negativa en todas las soluciones, lo que sugiere que se está utilizando una métrica inversa donde valores más negativos indican menor desgaste (figura 2).




Figura 2. Frente de Pareto para el análisis de fallas de engranajes.

La regresión lineal, por otro lado, presenta un coeficiente de determinación alto ($R^2 = 0,882$ para el desgaste y $R^2 = 0,963$ para la resistencia), lo que indica que el modelo predictivo es capaz de explicar la mayor parte de la variabilidad en los datos. No obstante, la regresión lineal no permite explorar múltiples objetivos

simultáneamente, lo que limita su capacidad para encontrar soluciones óptimas en escenarios donde existen conflictos entre minimizar el desgaste y maximizar la resistencia (figura 3).




Figura 3. Regresión Lineal para el análisis de fallas de engranajes.

En este sentido, NSGA-II ofrece un enfoque más robusto al proporcionar soluciones balanceadas entre ambos criterios. Sin embargo, la regresión lineal sigue siendo útil para evaluar la influencia de cada parámetro de diseño sobre las variables de desempeño y podría emplearse como filtro previo para NSGA-II, reduciendo el espacio de búsqueda y mejorando la eficiencia del algoritmo.

En términos de diseño de engranajes, estos resultados confirman que un módulo óptimo cercano a 5,0 y un ángulo de presión en el rango de 24° - 25° proporcionan las mejores soluciones en términos de resistencia y menor desgaste. Esto es consistente con estudios previos en optimización de engranajes, donde se ha demostrado que aumentar el módulo reduce la concentración de esfuerzos y mejora la resistencia estructural, aunque con un posible impacto en el tamaño y peso del engranaje. Para futuras mejoras, se recomienda explorar enfoques híbridos combinando NSGA-II con simulación numérica (FEM) o aprendizaje automático, lo que permitiría refinar aún más la optimización y validar experimentalmente las soluciones obtenidas.

DISCUSIÓN

Los resultados obtenidos mediante el algoritmo NSGA-II reflejan un frente de Pareto que ilustra soluciones óptimas en el diseño de engranajes, logrando un equilibrio entre la minimización del desgaste y la maximización de la resistencia estructural.⁽²²⁾ Este enfoque multiobjetivo permite identificar configuraciones donde ningún objetivo puede mejorarse sin comprometer el otro, lo cual es fundamental en problemas de ingeniería con objetivos conflictivos.

En este caso, se observa que módulos más altos ($\geq 4,5$) y ángulos de presión próximos a 25° favorecen una mayor resistencia mecánica (hasta 125.000 unidades) y tasas de desgaste reducidas. Estos hallazgos son consistentes con investigaciones previas, demostraron que un módulo elevado disminuye la concentración de esfuerzos, mejorando la resistencia a la flexión y al pitting que destaca la importancia de optimizar parámetros geométricos para reducir el estrés en los dientes.⁽²³⁾

La tendencia observada también indica que módulos y ángulos de presión bajos incrementan el desgaste, subrayando la influencia crítica de estos parámetros en la durabilidad. La métrica inversa del desgaste (valores negativos indican menor desgaste) sugiere una definición adecuada para el problema de optimización, alineándose con enfoques multiobjetivo.⁽²⁴⁾ Sin embargo, el aumento del módulo puede implicar un mayor tamaño y peso del engranaje, un aspecto que señalan como una limitación práctica en aplicaciones donde la ligereza es prioritaria.⁽²⁵⁾

Por otro lado, la regresión lineal aplicada muestra un alto coeficiente de determinación ($R^2 = 0,882$ para desgaste y $R^2 = 0,963$ para resistencia), lo que evidencia su capacidad para capturar la variabilidad de los datos y evaluar la influencia individual de los parámetros de diseño, utiliza modelos estadísticos para estimar el comportamiento de sistemas de engranajes.⁽²⁶⁾

No obstante, su limitación radica en su enfoque mono-objetivo, incapaz de resolver conflictos entre desgaste y resistencia simultáneamente, a diferencia de NSGA-II. Este contraste resalta la superioridad de algoritmos evolutivos multiobjetivo⁽²⁷⁾ para problemas de diseño complejo. Una estrategia híbrida, podría aprovechar la

regresión lineal como un filtro inicial para reducir el espacio de búsqueda, incrementando la eficiencia de NSGA-II, tal como se ha propuesto en optimizaciones previas con CAD/CAE.⁽²⁸⁾

Desde una perspectiva de diseño, los resultados sugieren que un módulo cercano a 5,0 y un ángulo de presión entre 24° y 25° ofrecen un compromiso óptimo, que revisan la optimización de engranajes cilíndricos.⁽²⁹⁾ Este rango mejora la capacidad de carga, aunque podría requerir ajustes según restricciones específicas de peso o espacio. Para avanzar, integrar NSGA-II con simulación numérica (FEM) o con aprendizaje automático permitiría validar experimentalmente las soluciones y refinarlas frente a condiciones reales, destacan como tendencia en optimización mecánica.⁽³⁰⁾

Al comparar los métodos destacando sus ventajas y desventajas se encuentra que NSGA-II (Optimización Multiobjetivo) permite soluciones óptimas en comparación al frente de Pareto, dado que explora relaciones entre tasa de desgaste y resistencia, pero no logra soluciones factibles, por lo que debe corregirse la formulación del problema.⁽³¹⁾

Por su parte la regresión Lineal realiza una predicción precisa (R^2 alto) la cual es fácil de interpretar y utilizar, pero no optimiza directamente. No encuentra el balance óptimo entre desgaste y resistencia.⁽³²⁾

Basado en los hallazgos encontrados se determinó NSGA-II demuestra ser una herramienta robusta que el algoritmo para el diseño de engranajes, superando las limitaciones de la regresión lineal en contextos multiobjetivo. Los parámetros óptimos identificados son coherentes con la literatura y ofrecen una base sólida para aplicaciones prácticas, aunque futuras investigaciones deberían considerar enfoques híbridos y validación experimental para maximizar su impacto en el diseño industrial.

CONCLUSIONES

En función del análisis los resultados analizados, se concluye que la optimización multiobjetivo mediante NSGA-II es altamente efectiva para mejorar la durabilidad y eficiencia de los engranajes mecánicos, al identificar parámetros de diseño clave que equilibran la minimización del desgaste y la maximización de la resistencia estructural.

Los hallazgos destacan que un módulo óptimo cercano a 5,0 y un ángulo de presión en el rango de 24°-25° son configuraciones ideales, ya que promueven una mayor resistencia mecánica (hasta 125.000 unidades) y reducen significativamente las tasas de desgaste. Estos parámetros, consistentes con la literatura, disminuyen la concentración de esfuerzos y mejoran la vida útil del engranaje, alineándose con el objetivo de optimizar el rendimiento general del sistema.

Se recomienda avanzar hacia metodologías integradas que combinen NSGA-II con simulación numérica (FEM) y aprendizaje automático, para validar experimentalmente las soluciones y afinar los parámetros bajo condiciones reales. Esta estrategia no solo consolidará los beneficios en durabilidad y eficiencia, sino que también posicionará el diseño de engranajes en la vanguardia de la ingeniería mecánica, cumpliendo plenamente con los objetivos establecidos.

REFERENCIAS BIBLIOGRÁFICAS

1. Fang X, Wen J, Cheng L, Yu D, Zhang H, Gumbsch P. Programmable gear-based mechanical metamaterials. *Nat Mater*. 2022;21(8):869-76. <http://dx.doi.org/10.1038/s41563-022-01269-3>
2. Marafona JD, Marques PM, Martins RC, Seabra JH. Mesh stiffness models for cylindrical gears: A detailed review. *Mech Mach Theory*. 2021;166:104472. <https://doi.org/10.1016/j.mechmachtheory.2021.104472>
3. Rajwar K, Deep K, Das S. An exhaustive review of the metaheuristic algorithms for search and optimization: taxonomy, applications, and open challenges. *Artif Intell Rev*. 2023;56(11):13187-257. <http://dx.doi.org/10.1007/s10462-023-10470-y>
4. Chen X, Hong J, Wang Y, Ma Y. Fatigue failure analysis of the central-driven bevel gear in a turboshaft engine arising from multi-source excitation. *Eng Fail Anal*. 2021;119:104811. <https://doi.org/10.1016/j.engfailanal.2020.104811>
5. Blekos K, Brand D, Ceschini A, Chou CH, Li RH, Pandya K, et al. A review on quantum approximate optimization algorithm and its variants. *PhysRep*. 2024;1068:1-66. <https://doi.org/10.1016/j.physrep.2024.03.002>
6. Shi ZY, Yu B, Song HX, Wang XY. Development of gear measurement technology during last 20 years. *China Mech Eng*. 2022;33(9):1009-24. <https://www.researchgate.net/journal/The-International-Journal-of-Advanced-Manufacturing-Technology-1433-3015>
7. Li M, Tang L. Parametric Modeling and Multi-Objective Optimization of Spiral Bevel Gears Based on NSGA-II Algorithm. *J Xihua Univ (Nat Sci Ed)*. 2025. <http://dx.doi.org/10.12198/j.issn.1673-159X.5543>

8. Alhijawi B, Awajan A. Genetic algorithms: Theory, genetic operators, solutions, and applications. *Evol Intell*. 2024;17(3):1245-56. <http://dx.doi.org/10.1007/s12065-023-00822-6>
9. Abderazek H, Hamza F, Yildiz AR, Sait SM. Comparative investigation of the moth-flame algorithm and whale optimization algorithm for optimal spur gear design. *Mater Test*. 2021;63(3):266-71. <http://dx.doi.org/10.1515/mt-2020-0039>
10. Xiang L, An C, Zhang Y, Hu A. Failure dynamic modelling and analysis of planetary gearbox considering gear tooth spalling. *Eng Fail Anal*. 2021;125:105444. <https://doi.org/10.1016/j.engfailanal.2021.105444>
11. Maraş S, Arslan H, Birgören B. Detection of gear wear and faults in spur gear systems using statistical parameters and univariate statistical process control charts. *Arab J Sci Eng*. 2021;46:12221-34. <http://dx.doi.org/10.1007/s13369-021-05930-y>
12. Pamukçu H, Yapıcıoğlu PS, Yeşilnacar Mİ. Investigating the mitigation of greenhouse gas emissions from municipal solid waste management using ant colony algorithm, Monte Carlo simulation and LCA approach in terms of EU Green Deal. *Waste Manag Bull*. 2023;1(2):6-14. <https://doi.org/10.1016/j.wmb.2023.05.001>
13. Rana V, Petare A, Kumar Jain N, Parey A. Using abrasive flow finishing process to reduce noise and vibrations of cylindrical and conical gears. *Proc Inst Mech Eng Part B J Eng Manuf*. 2022;236(10):1341-54. <http://dx.doi.org/10.1177/09544054221075875>
14. Younes EB, Changenet C, Bruyère J, Rigaud E, Perret-Liaudet J. Multi-objective optimization of gear unit design to improve efficiency and transmission error. *Mech Mach Theory*. 2022;167:104499. <https://doi.org/10.1016/j.mechmachtheory.2021.104499>
15. Yuan M, Li Y, Zhang L, Pei F. Research on intelligent workshop resource scheduling method based on improved NSGA-II algorithm. *Robot Comput Integr Manuf*. 2021;71:102141. <https://doi.org/10.1016/j.rcim.2021.102141>
16. El Mansouri MH, Talbi M, Tahiri Z, Nhila O, El Kafhali M, Sekkat H. Application of the pareto tool for the analysis of CT scanner failures. *J Fail Anal Prev*. 2023;23(5):2039-43. <http://dx.doi.org/10.1007/s11668-023-01748-y>
17. Ma H, Zhang Y, Sun S, Liu T, Shan Y. A comprehensive survey on NSGA-II for multi-objective optimization and applications. *Artif Intell Rev*. 2023;56(12):15217-70. <http://dx.doi.org/10.1109/ACCESS.2021.3070634>
18. Duan P, Yu Z, Gao K, Meng L, Han Y, Ye F. Solving the multi-objective path planning problem for mobile robot using an improved NSGA-II algorithm. *Swarm Evol Comput*. 2024;87:101576. <https://doi.org/10.1016/j.swevo.2024.101576>
19. He F, Ye Q. A bearing fault diagnosis method based on wavelet packet transform and convolutional neural network optimized by simulated annealing algorithm. *Sensors*. 2022;22(4):1410. <http://dx.doi.org/10.3390/s22041410>
20. Zhao D, Chen M, Lv J, Lei Z, Song W. Multi-objective optimization of battery thermal management system combining response surface analysis and NSGA-II algorithm. *Energy Convers Manag*. 2023;292:117374. <https://doi.org/10.1016/j.enconman.2023.117374>
21. Flek J, Dub M, Kolář J, Lopot F, Petr K. Determination of mesh stiffness of gear—Analytical approach vs. FEM analysis. *Appl Sci*. 2021;11(11):4960. <https://doi.org/10.3390/app11114960>
22. Qiu M, Zhang J, Wang H, Yang C, Tang Y, Zhang P. Multi-objective optimization design of wheel hub bearings based on Kriging-NSGA-II. *J Mech Sci Technol*. 2024;38(3):1341-53. <http://dx.doi.org/10.1007/s12206-024-0129-6>
23. Shi X, Li Y, Zhang S, Zhang Z. PB-MNSGA-II algorithm and its application for multi-objective optimization design of under-vehicle equipment. *Proc Inst Mech Eng Part C J Mech Eng Sci*. 2025;239(3):659-73. <http://dx.doi.org/10.1177/09544062241288925>

24. Zhang K, Shen R, Hu Z, Tang J, Sun Z, Ning A, et al. Dynamic modeling and analysis considering friction-wear coupling of gear system. *Int J Mech Sci.* 2024;275:109343. <https://doi.org/10.1016/j.ijmecsci.2024.109343>
25. Osuch-Słomka E, Michalczewski R, Mańkowska-Snopczyńska A, Kalbarczyk M, Wieczorek AN, Skótek E. Wear mechanisms of the working surface of gears after scuffing tests. *Materials.* 2024;17(14):3552. <http://dx.doi.org/10.3390/ma17143552>
26. Sugunesh AP, Vignesh S, Mertens AJ, Raj RN. Polymer gear failure prediction: A regression-Based approach using FEA and photoelasticity technique. *Eng Fail Anal.* 2024;165:108808. <https://doi.org/10.1016/j.engfailanal.2024.108808>
27. Pătrăușanu A, Florea A, Neghină M, Dicoiu A, Chiș R. A systematic review of multi-objective evolutionary algorithms optimization frameworks. *Processes.* 2024;12(5):869. <http://dx.doi.org/10.3390/pr12050869>
28. Jia H, Liang S, Zhao J, Li J, Dai H, Ji S. Improving accuracy and efficiency of the machined PEEK denture based on NSGA-II integrated GABP neural network. *Dent Mater.* 2024;40(11):e82-e94. <https://doi.org/10.1016/j.dental.2024.07.011>
29. Ni G, Liu Z, Song C, Liu S, Dong Y, Cao Y. Geometric parameter design and contact characteristics of beveloid gear and involute cylindrical gear transmission with crossed axes. *J Mech Sci Technol.* 2024;38(2):815-25. <https://doi.org/10.1007/s12206-024-0128-7>
30. Al-Haddad LA, Mahdi NM. Efficient multidisciplinary modeling of aircraft undercarriage landing gear using data-driven Naïve Bayes and finite element analysis. *Multiscale Multidiscip Model Exp Des.* 2024;7(4):3187-99. <http://dx.doi.org/10.1007/s41939-024-00389-4>
31. Gu Y, Ma Z, Guo Q, Wang Y. Performance analysis and optimization of a vehicular LT-PEMFC for maximum power density and efficiency based on NSGA-II algorithm. *Proc Inst Mech Eng Part D J Automob Eng.* 2024;09544070241286251. <http://dx.doi.org/10.1177/09544070241286251>
32. Manarikkal I, Elasha F, Mba D. Diagnostics and prognostics of planetary gearbox using CWT, auto regression (AR) and K-means algorithm. *Appl Acoust.* 2021;184:108314. <https://doi.org/10.1016/j.apacoust.2021.108314>

FINANCIACIÓN

Los autores no recibieron financiación para el desarrollo de la presente investigación.

CONFLICTO DE INTERESES

Los autores declaran que no existe conflicto de intereses.

CONTRIBUCIÓN DE AUTORÍA

Conceptualización: Rodrigo Rigoberto Moreno Pallares, Juan Carlos Quinchuela Paucar, Patricia Pilar Moyota Amaguaya, Luis Fernando Buenaño Moyano.

Investigación: Rodrigo Rigoberto Moreno Pallares, Juan Carlos Quinchuela Paucar, Patricia Pilar Moyota Amaguaya, Luis Fernando Buenaño Moyano.

Metodología: Rodrigo Rigoberto Moreno Pallares, Juan Carlos Quinchuela Paucar, Patricia Pilar Moyota Amaguaya, Luis Fernando Buenaño Moyano.

Redacción - borrador original: Rodrigo Rigoberto Moreno Pallares, Juan Carlos Quinchuela Paucar, Patricia Pilar Moyota Amaguaya, Luis Fernando Buenaño Moyano.

Redacción - revisión y edición: Rodrigo Rigoberto Moreno Pallares, Juan Carlos Quinchuela Paucar, Patricia Pilar Moyota Amaguaya, Luis Fernando Buenaño Moyano.