



UNIVERSIDAD AUTÓNOMA DE BAJA CALIFORNIA  
FACULTAD DE INGENIERÍA

# OPTIMIZACIÓN ESTRUCTURAL DE VÁLVULA DE MARIPOSA PARA REDUCCIÓN DE PESO

TESIS

QUE PARA OPTAR AL GRADO ACADÉMICO DE MAESTRA EN  
CIENCIAS.

PRESENTA:

**PERLA SUSANA PÉREZ MONTOYA**

**Director de Tesis: Dr. Alejandro Sebastián Ortiz Pérez**

**Co-Director de Tesis: Dr. Emmanuel Santiago Durazo Romero**

Diciembre de 2020.

Mexicali, Baja California, México.



## Agradecimientos

A mis padres y a mi hermana, por ser el principal motor en mi búsqueda de superación constante.

A mis amigos y compañeros de posgrado que siempre me apoyaron y dieron ánimos para seguir adelante.

A los doctores Alejandro Ortiz, Emmanuel Durazo y Virginia García por su paciencia, gran apoyo y guía cuando las cosas se pusieron difíciles.

A todas las personas que de alguna manera me ayudaron a llegar hasta donde estoy y me impulsaron a cumplir ésta meta.

## Resumen

La optimización en el diseño es cada vez más usada en la industria, ya que provee una manera mas económica y flexible de identificar configuraciones idóneas antes del desarrollo físico de algún componente o subsistema. Las mejoras componentes sencillos, pero con presencia constante y alto volumen dentro de la aeronave es una opción realista que se ajusta a las necesidades a corto plazo que la industria requiere.

Este proyecto comprende el análisis y optimización de una válvula de mariposa, la cual es utilizada principalmente dentro de los sistemas neumáticos para control de sangrado, aire acondicionado y presurización.

Por medio del uso de herramientas de análisis de elemento finito (FEA), Diseño asistido por computadora (CAD) y programación, se propuso una metodología de optimización multiobjetivo utilizando métodos heurísticos que permitió obtener generaciones de individuos que evolucionen dada una función objetivo particular.

Los resultados obtenidos arrojaron una disminución de esfuerzos equivalentes en un 14 % con respecto al modelo de la válvula original y un ahorro de aproximadamente 2 % de peso. Esto confirma el funcionamiento de la metodología y abre la posibilidad de utilizarla en otras familias de componentes similares.

## Abstract

Design optimization is increasingly used in the industry, as it provides a more economical and flexible way to identify suitable configurations before the actual production of a component or subsystem. Upgrading simple components with constant presence and high volume within the aircraft is a realistic option that meets the short-term needs that the industry requires.

This project includes the analysis and optimization of a butterfly valve, which is used mainly within pneumatic systems for bleeding control, air conditioning and pressurization.

Through the use of Finite Element Analysis (FEA), Computer Aided Design (CAD) and programming tools, a multiobjective optimization methodology was proposed using heuristic methods that allowed obtaining generations of individuals that evolve given a particular objective function.

The results obtained showed an equivalent stress reduction of 14% with respect to the original valve model and savings of approximately 2% in weight. This confirms the proper functioning of the methodology and opens the possibility of using it in other families of similar components.

# Índice

<b>Agradecimientos</b>	<b>I</b>
<b>Resumen</b>	<b>II</b>
<b>Abstract</b>	<b>III</b>
<b>1. Introducción</b>	<b>1</b>
1.1. Introducción . . . . .	1
1.2. Justificación . . . . .	6
1.3. Hipótesis . . . . .	8
1.4. Objetivos . . . . .	8
1.4.1. Objetivo General . . . . .	8
1.4.2. Objetivos Específicos . . . . .	8
1.5. Estructura del Proyecto . . . . .	9
<b>2. Estado del Arte</b>	<b>11</b>
<b>3. Fundamentos teóricos</b>	<b>18</b>
3.1. Fundamentos de diseño Mecánico: Mecánica de Sólidos . . . . .	18
3.1.1. Estados de Carga: Esfuerzo y deformación . . . . .	18
3.1.2. Concentración de Esfuerzos . . . . .	22
3.1.3. Criterio de Von Mises y Factor de seguridad . . . . .	22
3.2. Diseño de Válvulas de Mariposa . . . . .	25
3.2.1. Definiciones y conceptos básicos . . . . .	25
3.2.2. Materiales . . . . .	28
3.2.3. Superaleaciones . . . . .	29
3.2.4. Normativas de diseño y tolerancias en válvulas de mariposa .	31
3.2.5. Herramientas de Análisis . . . . .	32
3.3. Optimización de Diseño . . . . .	34
3.3.1. Metodología de diseño Tradicional . . . . .	34
3.3.2. Metodología de diseño Óptimo . . . . .	35
3.4. Principios de Optimización Estructural . . . . .	37
3.4.1. Tipos de Optimización Estructural . . . . .	37
3.4.2. Modelos computacionales heurísticos . . . . .	39
3.4.2.1. Redes neuronales . . . . .	39
3.4.2.2. Algoritmos Genéticos . . . . .	41
<b>4. Formulación y desarrollo del problema</b>	<b>44</b>
4.1. Metodología general . . . . .	44

---

4.2. Elección del componente . . . . .	46
4.3. Condiciones Iniciales . . . . .	47
4.3.1. Material . . . . .	48
4.3.2. Condiciones de operación . . . . .	48
4.3.3. Condiciones de Frontera . . . . .	49
4.4. Simplificación de Modelo en CAD y definición de las variables de diseño . . . . .	51
4.5. Script y Parametrización . . . . .	54
4.6. Análisis de Elemento Finito en condiciones iniciales . . . . .	55
4.7. Optimización Topológica . . . . .	59
4.8. Proceso de Optimización y Codificación . . . . .	60
4.9. Manipulación geométrica por medio de NURBS . . . . .	63
4.10. Definición de requerimientos y elección de Red Neuronal . . . . .	65
4.10.1. Algoritmos genéticos . . . . .	67
4.11. Integación con Phyton . . . . .	73
<b>5. Resultados</b>	<b>75</b>
5.1. Valores de entrada . . . . .	75
5.2. Cambio geométrico en las costillas . . . . .	77
5.3. Elección del Individuo Final . . . . .	79
5.4. Comparación contra diseño inicial . . . . .	81
<b>6. Conclusiones y recomendaciones</b>	<b>86</b>
6.1. Conclusiones generales . . . . .	86
6.2. Recomendaciones para trabajos futuros . . . . .	89

## Índice de cuadros

4.1. Propiedades del INCONEL 718. . . . .	48
4.2. Condiciones de temperatura y presión típica de la válvula de mariposa. . . . .	49
4.3. Análisis de Sensibilidad de Malla . . . . .	56
5.1. Promedio de puntos generados por generación para cada costilla. . . . .	77
5.2. Valores de referencia del modelo inicial. . . . .	79
5.3. Comparación del mejor individuo de cada generación. . . . .	79
5.4. Tabla de comparación de Resultados final. . . . .	85



## Índice de figuras

1.1. Importancia del proceso de diseño en ingeniería y su relación con el costo. Figura tomada de Dieter & Schdmit (2012) [13]. . . . .	1
1.2. Las válvulas como pieza fundamental de los sistemas hidráulicos y neumáticos de una aeronave. . . . .	5
3.1. Estado de esfuerzos en un elemento cúbico referencial . . . . .	20
3.2. Partes básicas en una válvula de mariposa . . . . .	26
3.3. Tipos de válvulas de mariposa: compensación cero, doble y triple, ordenadas de izquierda a derecha. . . . .	28
3.4. Diferentes materiales utilizados en la fabricación de un avión . . . . .	28
3.5. Uso de FEA Software en diseño aeroespacial y simetría del objeto . . . . .	34
3.6. Diagrama de diseño tradicional . . . . .	35
3.7. Diagrama de diseño óptimo. . . . .	36
3.8. Optimización de tamaño . . . . .	38
3.9. Optimización topológica . . . . .	38
3.10. Optimización de forma. . . . .	39
3.11. Ejemplo básico de una red neuronal. . . . .	40
3.12. Ejemplo básico del ciclo del algoritmo genético. . . . .	42
4.1. Mapa de Proceso . . . . .	44
4.2. Detalle del Ensamble. . . . .	47
4.3. Detalle de restricción en pasador. . . . .	50
4.4. Detalle de restricción en eje. . . . .	50
4.5. Detalle de restricción en diámetro externo. . . . .	51
4.6. Detalle de las variables de diseño. . . . .	52
4.7. Simplificación de DC. . . . .	53
4.8. División del modelo CAD para simplificación. . . . .	53
4.9. Vistas de modelo original: Vista isométrica, frontal y lateral. . . . .	54
4.10. Vistas de modelo Simplificado: Vista isométrica, frontal y lateral. . . . .	54
4.11. Condiciones de Frontera en ANSYS. . . . .	57
4.12. Resultados de Análisis inicial 1. . . . .	58
4.13. Resultados de análisis inicial 2. . . . .	58
4.14. Resultado de Optimización Topológica. . . . .	60
4.15. Mapa general de Optimización de Forma . . . . .	63
4.16. Representación básica de la costilla con NURBS. . . . .	64
4.17. Representación básica de la costilla con puntos. . . . .	64
4.18. Importación de modelo de Optimización a CAD para referencia . . . . .	65
4.19. Ejemplo de Red Backpropagation, tomado de [34]. . . . .	67
4.20. Diagrama de Optimización de forma . . . . .	73
5.2. Ejemplo de geometría de una costilla de Generación 10. . . . .	78

---

5.1. Puntos generados para la costilla 1 . . . . .	78
5.3. Comparación de esfuerzo equivalente promedio del mejor individuo de cada generación . . . . .	80
5.4. Comparación de masa del mejor individuo de cada generación. . . .	81
5.5. Modelo inicial: Esfuerzo. . . . .	82
5.6. Modelo inicial: Deformación. . . . .	82
5.7. Resultado Final: Esfuerzo. . . . .	83
5.8. Resultado final: Deformación. . . . .	84
5.9. Modelo Final . . . . .	85

## Abreviaturas y símbolos

**CAD** Computer Aided Design. 3, 62, 64

**CAE** Computer Aided Engineering. 3

**CAM** Computer Aided manufacturing. 3

**DOE** Design of Experiments. 16

**ES** Evolutionary Strategies. 13

**FEA** Finite Element Analysis. 12, 62

**GA** Genetic Algorithm. 13, 14, 16, 60, 65, 67, 69, 72, 73, 79, 86

**NN** Neural Network. 13, 15, 16, 66, 67, 76, 86


**PSO** Particle Swarm Optimzation. 13, 14

# 1. Introducción

## 1.1. Introducción

Los últimos años de la industria aeroespacial han estado enmarcados por un entorno altamente globalizado. En el panorama actual, factores como el alza del precio de los combustibles y el enfoque en ahorro de recursos naturales ha provocado la creación de múltiples iniciativas por parte de los gigantes aéreos para invertir en tecnologías que a su vez generen reducción de costos y tiempos de manufactura. Lo anterior implica un gran reto para el ramo de la ingeniería, pues es necesario adaptar dichas tecnologías en ambientes industriales de manera funcional y puntual para crear aeronaves que no solo cumplan con los estándares de calidad y eficiencia del mercado, sino que sobrepasen y mejoren las características actuales. En la figura 1.1 se puede observar como especialmente las fases de diseño conceptual y diseño de producto constituyen mas de la mitad del costo presupuestado en un proyecto, dejando en claro el impacto y oportunidad que representan los esfuerzos para reducción de costos en dichas etapas.

**Figura 1.1:** Importancia del proceso de diseño en ingeniería y su relación con el costo. Figura tomada de Dieter & Schdmit (2012) [13].



Dicho esto, se puede intuir que las decisiones de diseño tienen por lo general influencia significativa en las estimaciones de costos y gastos operativos, esto dada su relación de manera general con una gran variedad de disciplinas tales como: diseño estructural, de productos, selección de materiales, transferencia de calor, manufactura, ergonomía, estética, economía, entre otras. Por lo cual es importante entenderlos y tomarlos en cuenta cuando se decida la configuración final de la misma [16]

El diseño siempre ha sido considerado como un proceso iterativo, el cual está en continua actualización para cumplir con el objetivo deseado. La metodología actual provee distintas maneras de resolver los problemas más comunes multidisciplinariamente. Debido a la cantidad de variables involucradas en los procesos de diseño, se pueden generar diversas soluciones con la finalidad de optimizar cada una de ellas.

Es bien sabido que el diseño adecuado de un componente asegura su correcto funcionamiento y al mismo tiempo saca partido a las capacidades máximas de manufactura disponibles, por ello se dice que la mayor diferencia entre el proceso de diseño en tecnología y el proceso de diseño en ingeniería son el análisis y la optimización. Mientras que en el análisis, modelos matemáticos y principios científicos son utilizados para ayudar al diseñador a predecir resultados, la optimización es un proceso sistemático que ayuda a identificar la configuración óptima de una serie de posibles opciones, incluso de una serie de opciones infinitas con la ayuda de ciertas restricciones de diseño [18]. Solo en las décadas recientes se ha optado por técnicas y métodos de optimización planteando distintas formas de resolver problemas complejos para obtener soluciones y mejoras en los procesos y reducción de costos. La aplicación de dichos métodos a problemas reales en ingeniería representa un área de oportunidad que, gracias a la gran capacidad de las computadoras actuales, ha empezado a desarrollarse tanto académica como

industrialmente.

La optimización en el diseño es cada vez más usada en la industria, ya que provee una manera mas económica y flexible de identificar configuraciones idóneas antes del desarrollo físico de algún componente o subsistema. Asimismo, el uso rutinario de CAD (Computer Aided Design), CAM (Computer Aided manufacturing) y CAE (Computer Aided Engineering) en la industria del diseño facilita aún más ésta práctica. Dentro de este rubro, la optimización estructural se ha convertido en una herramienta útil para reducción de pesos y mejora de prototipos. De manera rápida, podemos clasificar la optimización estructural en tres categorías, que serán descritas de manera más detallada en el siguiente capítulo: Optimización de tamaño, de forma y de topología. Cada uno de estos se centra en diferentes aspectos de la estructura. Por ejemplo, la optimización de tamaño se refiere al tamaño físico de los miembros dentro de una estructura, mientras que la forma se refiere al diseño geométrico y la topología a la configuración interna de miembros de una estructura [29]. A su vez, existen varias técnicas que pueden ser usadas para determinar el valor óptimo dentro del grupo de variables. Estos pueden ser agrupados en dos grandes categorías: Métodos basados en gradientes y métodos heurísticos[22]. Los últimos más utilizados habitualmente en problemas de optimización por su flexibilidad y adaptabilidad a múltiples escenarios.


La optimización estructural se puede ver como una fusión entre la ingeniería, matemáticas, ciencia y tecnología, que tiene la meta de llevar a cabo la mejor función de una estructura que puede ser tan compleja como un puente, un vehículo espacial o tan simple como un elemento mecánico [43]. Es lógico afirmar que mientras más complejo sea el sistema que se desee optimizar, más grande será el número de variables involucradas y los factores que afecten el resultado.

En el caso de las aeronaves, el múltiple conjunto de subsistemas involucrados en

---

su funcionamiento implicaría un planteamiento de optimización muy complejo que probablemente no sería factible en la industria, pues cambiar por completo sistemas que están en funcionamiento en el mercado requiere años de desarrollo y pruebas. Por lo tanto, optar por mejoras en sistemas y componentes más sencillos, pero con presencia constante y alto volumen dentro de la aeronave es una opción realista que se ajusta a las necesidades a corto plazo que la industria requiere. Ejemplos de ello son los actuadores, tuberías y válvulas, como se puede observar en la figura 1.2. Estos últimos son componentes mecánicos que controlan el flujo y presión de líquidos y gases y son parte de muchas máquinas usadas a diario que pueden realizar una variedad de funciones. En una aeronave se utilizan una gran cantidad de válvulas con diferentes propósitos: para control de aire, regulación de presión, suministro de combustible, control de emergencias, anti-congelamiento, etc. Estos son componentes muy versátiles y que constituyen un mercado importante dentro de la industria aeroespacial. Dentro de la variedad de válvulas en el sector y especialmente dentro de los sistemas neumáticos para control de sangrado, aire acondicionado y presurización, las válvulas de mariposa son el tipo más utilizado dada su simplicidad y son normalmente favorecidas ya que son más baratas en comparación con otros diseños [19].

**Figura 1.2:** Las válvulas como pieza fundamental de los sistemas hidráulicos y neumáticos de una aeronave.



Todos estos aspectos mencionados anteriormente hacen que este tipo de válvulas sean una opción atractiva para aquellas aplicaciones donde la caída de presión es relativamente baja [10], lo cual nos permite tener condiciones más estables para las restricciones iniciales y así poder desarrollar un método de optimización más sencillo que, a su vez, pueda ser adaptado para otras familias de componentes similares y eventualmente tendrá un impacto significativo en ahorro de costos y reducción de peso.



## 1.2. Justificación

Con el acelerado ritmo tecnológico desarrollado en los últimos 20 años, el proceso de diseño tradicional en la ingeniería puede ser visto de cierta manera como obsoleto. En este sentido, la optimización estructural ha cobrado importancia al ofrecer la posibilidad de encontrar soluciones fuera de la línea de pensamiento habitual analizando un gran número de variables simultáneamente. A su vez, el aumento de las capacidades computacionales ha mejorado considerablemente, lo cual propicia el desarrollo de algoritmos, software y tecnologías asociadas a la optimización. Por lo cual, esta técnica de diseño comienza a formar cada vez parte mas importante dentro de las herramientas del ingeniero de diseño.

Si bien, la mayoría de las investigaciones sobre optimización estructural se encuentran enfocadas en el desarrollo de metodologías, muy pocas de ellas han incluido restricciones reales de los componentes como variables de diseño, ya que la tarea de involucrar parámetros de manufactura se ve limitada a la misma capacidad de los procesos. En un principio esto llegó a ser impedimento para muchas de las soluciones creadas por las técnicas de optimización, pero hoy en día han mejorado al grado de ser cada vez más compatibles con nuevas tecnologías como la manufactura aditiva [8] que permiten que el proceso de diseño no se vea frenado ni restringido.

A su vez, el uso de métodos heurísticos brinda la posibilidad de explorar soluciones nuevas que en un principio no pudieran ser abordadas dada la flexibilidad que permiten en el numero de variables de entrada y salida. Se pretende mostrar que su implementación dentro del proceso de diseño debe ser seriamente considerada de manera habitual y que involucra un cambio de pensamiento en el diseñador.

---

Así pues, la inquietud de ahondar mas en este tema viene relacionada con el gran campo de investigación que hay disponible y en las oportunidades de mejora que existen en el sector industrial dada la metodología de diseño tradicional.

De manera específica, este proyecto tiene la finalidad de analizar diferentes opciones de optimización estructural enfocándose en uno de los componentes mas utilizados en el sistema hidráulico de una aeronave. Considerando la válvula mariposa se busca una mejora en términos de costo-confiabilidad.

## 1.3. Hipótesis

La metodología de optimización estructural multiobjetivo a través de estrategias metaheurísticas logra un resultado de reducción de peso en una válvula de mariposa sin afectar el comportamiento estructural del componente.

## 1.4. Objetivos

### 1.4.1. Objetivo General

Obtener una válvula mejorada estructuralmente con respecto a otra válvula genérica tipo mariposa de referencia mediante un enfoque topológico y de forma a través de una optimización multiobjetivo para reducir peso.

### 1.4.2. Objetivos Específicos

- Caracterización del comportamiento del componente bajo condiciones promedio de operación.
- Definición de la función multi-objetivo y del espacio de diseño genérico.
- Generación de una red neuronal entrenada que provea la cantidad de población necesaria para la población general.
- Desarrollo del algoritmo de la optimización y aplicación de las estrategias de optimización con algoritmos genéticos
- Evaluación de resultados.
- Resolución de la opción más idónea al diseño del componente.

## 1.5. Estructura del Proyecto

1. Desarrollo de Estado del Arte (antecedentes): Artículos y publicaciones actuales que aborden el tema y el alcance programado, para así obtener un punto de partida en relación con el proyecto que se realizará.
  - a) Búsqueda de artículos con palabras clave.
  - b) Depuración de información relevante.
  - c) Redacción de estado del arte.
2. Familiarización con softwares.
  - a) Realización de tutoriales.
  - b) Realización de prácticas para mejorar fluidez.
3. Elección de componentes para optimización: Dada la complicación de analizar un subsistema completo dentro de las estructuras de las aeronaves, se optará por la elección de un componente o subsistema adecuado para el caso de estudio.
  - a) Selección del tipo de válvula.
  - b) Simplificación de las variables de diseño.
4. Determinación de condiciones de operación y análisis previo del componente.
  - a) Comprensión y determinación de las condiciones de operación del componente, así como las cargas y restricciones que son aplicables al mismo.
  - b) Ejecución de análisis de elemento finito para comprobar estado inicial: Con la ayuda de un programa de FEM especializado de elementos finitos, se llevará a cabo un análisis estructural en el componente actual para observar el comportamiento del mismo antes tales condiciones.
5. Estudio de métodos heurísticos.



## 2. Estado del Arte

Las técnicas de optimización estructural asistida por computadora han sido utilizadas desde hace algunas décadas en diversos campos de la ingeniería. A través de los últimos años, los esfuerzos se han enfocado en desarrollar estas técnicas de optimización, tal como el compendio presentado por Muller [30] demuestra.

La optimización estructural, con especial énfasis en las categorías de optimización de topología y de forma, han sido ampliamente investigadas y desarrolladas en el campo de la ingeniería aeroespacial como lo muestra Munk [32]. Ejemplos de éstos trabajos incluyen: Los de Niemann [36], quien hace uso de optimización topológica en estructuras del fuselaje en una aeronave, los de Benaouali [5] en relación al tamaño y forma de un ala y, los de Ajay [3] para mejorar un impulsor sin modificar los diámetros de entrada y salida. Lo anterior muestra el impacto que ha tenido la optimización estructural en las primeras etapas de diseño conceptual.

Si bien en un principio las capacidades de manufactura llegaron a ser impedimento para muchas de las soluciones creadas por las técnicas de optimización, hoy en día éstas han mejorado al grado de ser cada vez más compatibles, como lo muestra Mirzendehtdel [28], quien hace una aproximación con utilización en la manufactura aditiva .

Por ello y con el objetivo de atacar varios problemas a la vez, las aproximaciones a problemas con optimizaciones multidisciplinarias han sido adoptadas como preferidas por múltiples autores a lo largo de la última década. Larson [20] por ejemplo, propone una optimización multi-objetivo de dos etapas para topología y

forma. Munk [31] hizo también un trabajo de optimización multi-objetivo pero de manera puramente conceptual. Autores como Ahrari [2] consideraron de manera individual los tres aspectos secuencialmente en una investigación multinivel y otros como Mortazavi [29] desarrollaron los 3 de manera simultánea, lo que prueba el éxito que tienen los enfoques múltiples.

Sin embargo, independientemente del tipo de optimización que se realice, uno de los aspectos que dificulta la resolución de un problema de este tipo es, el llamado espacio de diseño, el cual nos ayuda a definir las variables que están presentes en el problema. En el trabajo presentado por Ahrari [2] se menciona que en problemas estructurales podemos tener una gran cantidad de variables (discretas, continuas y hasta booleanas).

Para ayudar a resolver lo anterior, la mayoría de los trabajos actuales de optimización estructural incluyen como paso obligatorio, la resolución de la geometría por medio de un análisis de elementos finitos (Finite Element Analysis, FEA por sus siglas en inglés); ya que como se mencionaba, desde hace varias décadas por Vanderplaats [45]: “Dichos análisis pueden usarse para determinar las sensibilidades de los parámetros de diseño en los métodos de programación matemática para resolver problemas de optimización”. Adicionalmente, esto lo presentan diversos autores como Sigmund [42], quien a principios de los 2000 proponía una integración utilizando FEA en Matlab. Trabajos más recientes como los de Zhu [47], Kim [19], Renzi [39] y Corbera [11] demuestran además, que es posible realizar análisis más complejos en primera etapa, no solo en a componente, si no también a ensambles completos.

Ahora bien, los problemas típicos de optimización requieren en cierta medida,

una etapa de iteración para llegar al resultado más aproximado al ideal. Para esto, es común encontrar en la literatura el uso de estrategias computacionales metaheurísticas que, como explica Melian [26], son de gran utilidad para la resolución de problemas de alto rendimiento. Diversas estrategias metaheurísticas se han utilizado en materia de optimización estructural. Entre ellas, podemos encontrar entre las más populares (por sus siglas en inglés): Estrategias evolutivas (Evolutionary Strategies, ES), Enjambre de partículas (Particle Swarm Optimization, PSO), Redes neuronales (Neural Network, NN) y Algoritmos genéticos (Genetic Algorithm, GA).

Las estrategias evolutivas (ES), son una técnica desarrollada inicialmente con la meta de resolver problemas de optimización discretos y continuos, principalmente experimentales y considerados difíciles. Trabaja con vectores de números reales con desviaciones estándar que codifican las posibles soluciones de problemas numéricos. Utiliza recombinación o cruce (*crossover aritmético*), mutación y la operación de selección, ya sea determinística o probabilística, elimina las peores soluciones de la población y no genera copia de aquellos individuos con una aptitud por debajo de la aptitud promedio [25]. Han sido muy utilizadas en temas estructurales tal y como lo aborda Munk [32], al hacer un análisis profundo de sus características principales y Querin [38] que en su libro muestra una serie de aplicaciones a diversos problemas de optimización estructural. Sin embargo, en problemas complejos, llegan a ser inflexibles ya que sus mecanismos de selección son limitados.

El llamado enjambre de partículas (PSO), a diferencia de las ES no usa selección y por lo general, como lo menciona Kelley [18]: “Todos los miembros de la población sobreviven desde el comienzo de una prueba hasta el final y sus interacciones dan como resultado una mejora iterativa de la calidad de las soluciones de problemas a



lo largo del tiempo”. Varios trabajos se han realizado en relación a optimización de forma con PSO, teniendo como ejemplos los realizados por Nickabadi, Ebadzadeh, & Safabakhsh [35] y Dos Santos [14]. Una de las desventajas de este método es la posible falta de diversidad en las generaciones finales dado que los individuos se mantienen a lo largo de las iteraciones.

Los algoritmos genéticos (GA), por su parte, modelan el proceso de evolución como una sucesión de frecuentes cambios en los genes, con soluciones análogas a cromosomas. Estas trabajan con una población de cadenas binarias para la representación del problema, y el espacio de soluciones posibles es explorado aplicando transformaciones a ciertas soluciones candidatas [25]. La gran ventaja de los algoritmos genéticos con respecto a todos los métodos anteriores es que son intrínsecamente paralelos. La mayoría de los otros algoritmos son en serie y sólo pueden explorar el espacio de soluciones hacia una solución en una dirección al mismo tiempo, y si la solución que descubren resulta sub-óptima, no se puede hacer otra cosa que abandonar todo el trabajo hecho y empezar de nuevo. Sin embargo, ya que los (GA) tienen descendencia múltiple, pueden explorar el espacio de soluciones en múltiples direcciones a la vez. Zhu [48], hace énfasis en el uso de algoritmos genéticos en el diseño como punto vital para el desarrollo del proceso de optimización y Renzi [39] crea una optimización basada en la utilización de GA dentro de un llamado entorno integrado de diseño, el cual demuestra que los algoritmos genéticos son adecuados para fines de optimización general debido a su alta robustez y la capacidad de manejar funciones de acondicionamiento físico complejas. El trabajo de Corbera [10] es de especial interés, ya que utiliza los algoritmos genéticos para su implementación de optimización multi-objetivo, sustentando así la versatilidad de ésta última estrategia.

Las redes neuronales (NN), por su parte, entran en una categoría diferente de los modelos bio-inspirados. Han sido desarrolladas desde hace años y están mucho más enfocadas en el procesamiento de datos para finanzas y predicción a futuro [3]. Sin embargo, han sido también utilizadas en conjunción con otras estrategias meta-heurísticas para resolver problemas complejos como muestran los trabajos de Majdi & Beiki [24], en los cuales utilizaron una red neuronal y un algoritmo genético para predecir la deformación de distintas masas de rocas. Esto es debido a que las redes neuronales son especialmente útiles para generar poblaciones distribuidas.

Como bien se mencionó anteriormente, las válvulas de mariposa son muy utilizadas en la industria para control de fluidos y en aplicaciones donde se tiene una caída de presión relativamente baja y volúmenes de trabajo altos. Se comenzaron a utilizar inicialmente donde un cierre hermético no era absolutamente necesario. Sin embargo, a lo largo de los años, estas válvulas se han fabricado con sellos bastante herméticos hechos de caucho o materiales elastómeros que proporcionan un buen cierre similar a otros tipos de válvulas [27]. Los primeros estudios que se llevaron a cabo para válvulas de mariposa fueron realizados experimentalmente para su caracterización en el entorno hidrodinámico. Varios trabajos como los de Kim & Kimura [37], M.J. & Dutton [12] y Chaiworapuek [9] muestran el comportamiento de este componente y su entorno. Por su parte, Zaimović-Uzunović, Ajan, Lemeš [21] realizaron la optimización de la carcasa de una válvula de mariposa para reducir peso utilizando análisis estructural como base y llevando a cabo una reducción en el grosor de las paredes de la misma. Por su parte, Shin, Yoon, J.Y., 'I&' Park [41] hicieron un estudio estructural de los componentes de una válvula de mariposa y posteriormente evaluaron su confiabilidad. Trabajos como los de Nagpurkar & Tajane [33], el anteriormente mencionado de Kim et al [19] y Song, Wang, Baek, & Park [44], detallan y describen el funcionamiento de la válvula e identifican dos

posiciones de trabajo dentro del funcionamiento: en posición completamente abierta (90 grados de referencia) y cerrada (en 0 grados).

Con toda la teoría anterior como base, se han aplicado una variedad de técnicas de diseño y optimización para mejorar el rendimiento y la estabilidad de las válvulas mariposa. Entre los estudios más destacados en este campo están los realizados por Sangmo, Da-Eung, Kuk-Kyeom, & Jun-Oh [17], quienes llevaron a cabo una optimización de forma por medio de diseño de experimentos (DOE, Design of Experiments por sus siglas en inglés). La investigación de Corbera Caraballo [11] propone una optimización global en una válvula de mariposa y su desarrollo toma en cuenta el factor de seguridad estructural, el peso y la influencia de la dinámica de fluidos. En su investigación hay dos fases que se llevan a cabo, la primera es una optimización topológica para evaluar la mejor distribución de material y subsecuentemente, la optimización de forma se lleva a cabo por medio de algoritmos genéticos. Corbera et al. [11] propone una optimización orientada al 3D mientras que los trabajos de Song et al. [44] son presentados en dos dimensiones.

En este trabajo tomamos como base lo descrito por los autores anteriores y optaremos por utilizar una técnica combinada de redes neuronales (NN) y algoritmos genéticos (GA). Ya que, aunque todas las estrategias meta-heurísticas tienen puntos favorables que tomar en cuenta, las redes neuronales (NN) muestran comportamiento favorable para la creación de poblaciones (que usaremos en las primeras etapa de optimización) y por su parte los algoritmos genéticos (GA) con su robustez permiten adecuar nuestros requerimientos de funciones objetivo a detalle.

Es importante mencionar que, aunque en un principio las capacidades de manufactura llegaron a ser impedimento para muchas de las soluciones creadas por

las técnicas de optimización, hoy en día, éstas han mejorado al grado de ser cada vez más compatibles, como muestra Mirzendehtdel [28] quien hace una aproximación con utilización en la manufactura aditiva. Esto permite más libertad en función de los cambios de diseño a efectuar, especialmente en etapas tempranas de desarrollo de producto.

---

## 3. Fundamentos teóricos

### 3.1. Fundamentos de diseño Mecánico: Mecánica de Sólidos

#### 3.1.1. Estados de Carga: Esfuerzo y deformación

La función primordial de una componente o sistema estructural es la transmisión de fuerzas o carga. Cuando se aísla una superficie interna, la fuerza y el momento totales que actúan sobre la superficie se manifiestan a sí mismos como distribuciones de fuerzas a través de toda el área. La distribución de fuerza que actúa en un punto sobre la superficie es única y tendrá componentes en las direcciones normal y tangencial llamados esfuerzo normal y esfuerzo cortante tangencial, respectivamente[23]. El esfuerzo en un punto P es definido pasando la sección de un plano a través de un punto y considerando fuerza por unidad de área en un elemento diferencial. El vector de esfuerzo en el punto P del plano del cual su vector normal es  $n$  se puede representar como:

$$t_n(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F}{\Delta A} \right) \quad (3.1)$$

Donde:  $\Delta A$  es el área del elemento diferencial y  $\Delta F$  como el vector de esfuerzo en el punto P. Asimismo podemos definir el esfuerzo normal (Ecuación 3.2) y el cortante (Ecuación 3.3) considerando los componentes de fuerza en las direcciones del plano normal ( $\Delta F_n$ ) y tangencial ( $\Delta F_t$ ) como:

$$\sigma_n(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F_n}{\Delta A} \right) \quad (3.2)$$

$$\tau_n(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F_t}{\Delta A} \right) \quad (3.3)$$

Si la dirección de  $\sigma$  es saliente de la superficie se considera un esfuerzo de tensión y es un esfuerzo normal positivo. Si  $\sigma$  entra hacia la superficie es un esfuerzo compresivo y comúnmente se considera una cantidad negativa. Ya que un número infinito de planos pueden pasar por un punto  $P$  dado, el estado de esfuerzo en el punto será claramente el estado en la sección del plano considerado. La usual práctica es definir el esfuerzo en términos de planos normales quienes están a lo largo de las direcciones coordenadas. Para un sistema coordinado los esfuerzos en un plano normal y cortante, respectivamente, están dados de la siguiente manera:

$$\sigma_X(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F_X}{\Delta A} \right); \sigma_Y(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F_Y}{\Delta A} \right); \sigma_Z(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F_Z}{\Delta A} \right) \quad (3.4)$$

$$\tau_X(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F_X}{\Delta A} \right); \tau_Y(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F_Y}{\Delta A} \right); \tau_Z(P) = \lim_{\Delta A \rightarrow 0} \left( \frac{\Delta F_Z}{\Delta A} \right) \quad (3.5)$$

Por lo tanto podemos entonces definir los componentes (o vectores) del estado de esfuerzos en un punto  $P$  en términos de los planos normales a lo largo de los 3 ejes, dado como resultado 9 componentes de esfuerzo:

Eje X:

$$t_X = (\sigma_X, \tau_{XY}, \tau_{XZ})^T \quad (3.6)$$

Eje Y:


$$t_Y = (\tau_{YX}, \sigma_Y, \tau_{YZ})^T \quad (3.7)$$

Eje Z:

$$t_Z = (\tau_{ZX}, \tau_{ZY}, \sigma_Z)^T \quad (3.8)$$

En la figura 3.1 se muestra de manera mas gráfica la explicación detrás de estas ecuaciones. Podemos observar que en las caras escondidas del cubo, los vectores normales van en dirección opuesta a las mostradas.

**Figura 3.1:** Estado de esfuerzos en un elemento cúbico referencial



Normalmente se suelen escribir estos vectores de esfuerzos de manera matricial, para formar así el llamado Tensor de esfuerzos, el cual, esta formado de 9 variables de esfuerzo:

$$S = \begin{pmatrix} \sigma_X & \tau_{XY} & \tau_{XZ} \\ \tau_{YX} & \sigma_Y & \tau_{YZ} \\ \tau_{ZY} & \tau_{ZY} & \sigma_{XZ} \end{pmatrix}$$

Con la condición de simetría del tensor de esfuerzos, podemos observar que hay igualdades dentro de los componentes de esfuerzo cortante, por lo cual eliminamos 3 incógnitas dentro de los componentes de esfuerzo:

$$\tau_{XY} = \tau_{YX}; \tau_{YZ} = \tau_{ZY}; \tau_{ZX} = \tau_{XZ} \quad (3.9)$$

En un entorno real, la distribución interna de fuerza en un miembro, a una cierta

distancia del punto de la aplicación de una fuerza local, depende solamente de la magnitud y ubicación de la fuerza resultante. Para calcular el comportamiento de un miembro sujeto a una carga de tensión pura es necesario tener cierta información de las propiedades mecánicas del material. Tal información se obtiene, generalmente, por medio de una prueba de ensayo a la tensión [23].

Dentro de la típica representación de la curva de esfuerzo-deformación, tenemos el llamado rango elástico, el cual forma la porción lineal de la curva. Si se detiene la carga dentro del rango elástico y se permite que decrezca hasta cero, la deflexión también decrecerá hasta cero. El *comportamiento elástico* se caracteriza por la ausencia de deformación permanente al retirar la carga. Este principio constituye la Ley de Hooke, que se puede establecer como: La deformación es proporcional a la carga. Debido a que el comportamiento de muchos materiales sigue esta ley casi por completo, la Ley de Hooke es muy importante y base de la teoría de la elasticidad. Esta ley no se limita solamente a la carga axial, sino a cualquier forma de carga, como en el caso de la aplicación de momentos.

Los experimentos muestran que para metales, y muchos otros materiales, la deformación se distribuye uniformemente a lo largo de la longitud, hasta la carga máxima. Más allá de este punto, el desplazamiento adicional ocurre un estrechamiento localizado en una longitud relativamente corta. Algunos materiales se rompen (punto de ruptura) cuando la carga se incrementa, antes de que empiece el estrechamiento. El desplazamiento por unidad de longitud se llama *deformación*. La deformación, en ingeniería, se define como un desplazamiento por unidad de longitud original.



### 3.1.2. Concentración de Esfuerzos

La concentración de esfuerzos ocurre en aquellos lugares donde existen cambios abruptos en la geometría del material, que puede ser por filetes, orificios, etc. Otras formas de concentrar los esfuerzos puede ser la discontinuidad en el material (imperfecciones), esfuerzos residuales, soldaduras, trabajo en frío. Las concentraciones de esfuerzos en un material frágil deben considerarse en el diseño. La razón de esto es que si el esfuerzo último se alcanza en unas cuantas fibras considerablemente cargadas, las fibras del materia se romperán, aunque la intensidad del esfuerzo promedio quede debajo del esfuerzo. Estas pocas fibras rotas forman una grieta diminuta que reduce aun mas el área total de la sección. Una grieta progresiva se desarrolla rápidamente haciendo que se fracture todo el miembro. Por otro lado, si el material es dúctil y esta sujeto a cargas estáticas, las concentraciones de esfuerzos no son significativos.

Tal y como pasa en una parte móvil de una máquina o en un miembro de un puente, las concentraciones de esfuerzo se deben de considerar mas a fondo. Si unas cuantas fibras se cargan repetidamente hasta una alta intensidad y después se descargan, causa que el material se pueda desgastar y esas fibras puedan fracturarse. Esto provoca que se reduzca el área en la sección transversal y como consecuencia mas fibras se sobrecargaran causando que desarrolle una grieta progresiva hasta llegar a fracturar el miembro.

### 3.1.3. Criterio de Von Mises y Factor de seguridad

Dado lo anterior, una de las tareas más importantes en la mecánica de sólidos es la determinación de los esfuerzos en un punto arbitrario de un elemento de maquina sujeto a fuerzas arbitrarias.

Si es posible determinar el estado de esfuerzos en un punto arbitrario del elemento de una máquina o componente, es posible determinar si dicho elemento puede soportar las fuerzas a las que está sujeto. Esta determinación involucra la selección y aplicación de una teoría de falla, apropiada al material de que está formado el elemento de máquina, sea dúctil o frágil, y el tipo de carga, sea estática o dinámica.

Las direcciones principales están en dirección del vector normal unitario para el plano donde el esfuerzo cortante es nulo y el esfuerzo normal máximo. Fuera de la diagonal principal, los términos en el tensor de esfuerzos  $S$  son cortantes, los que están en diagonal principal del tensor siguen la dirección de los planos principales y son los esfuerzos principales. Podemos definir lo anterior con la siguiente fórmula:

$$(S - \sigma I)n_p = 0 \quad (3.10)$$

Donde  $\sigma$  es un esfuerzo principal,  $I$  es una matriz de identidad 3x3 y  $n_p$  es un vector normal al plano principal. La solución del determinante  $Det(S - \sigma I) = 0$ , por su parte, corresponde a un conjunto de tres eigenvalores, a cada uno de los cuales corresponde un eigenvector. Los eigenvalores son los esfuerzos principales. Los esfuerzos principales son ordenados acorde a sus valores algebraicos. Se representa en el máximo esfuerzo cortante en algún plano dado como a continuación:

$$\tau_{max} = \frac{\sigma_1 - \sigma_3}{2} \quad (3.11)$$

En donde  $\sigma_1$  es el esfuerzo principal máximo,  $\sigma_3$  es el esfuerzo principal mínimo y  $\tau_{max}$  actúa en un plano inclinado a  $45^\circ$  en las direcciones de  $\sigma_1$  y  $\sigma_3$ .

Para determinar el esfuerzo último y de cedencia de los materiales, se deben llevar a cabo exámenes a probeta cargadas en una dirección. Para sólidos 3D, se puede convertir el estado de esfuerzos tridimensional en un valor equivalente que representa

los esfuerzos de falla de un cuerpo. El criterio mas utilizado para metales es el del Von Mises, el cual asume que el esfuerzo de falla ocurre cuando el valor del esfuerzo cortante es igual al esfuerzo cortante octaédrico en cedencia en una prueba de tensión uniaxial. Como aclaración, un cuadro octaédrico es aquel plano que tiene ángulos iguales en dirección con el esfuerzo principal. El esfuerzo en este plano es conocido como esfuerzo cortante octaédrico. Se puede representar usando la transformación de esfuerzos para un plano inclinado como:

$$\sigma_{Oct} = \frac{\sigma_1 + \sigma_2 + \sigma_3}{3} \quad (3.12)$$

$$\tau_{Oct} = \frac{1}{3} \sqrt{(\sigma_1 - \sigma_2)^2 + (\sigma_2 - \sigma_3)^2 + (\sigma_3 - \sigma_1)^2} \quad (3.13)$$

Y si lo representamos en términos de las componentes de esfuerzo normal y cortante del tensor de esfuerzos, tendremos algo como:

$$\tau_{Oct} = \frac{1}{3} \sqrt{(\sigma_1 - \sigma_2)^2 + (\sigma_2 - \sigma_3)^2 + (\sigma_3 - \sigma_1)^2 + 6[(\tau_{XY})^2 + (\tau_{YZ})^2 + (\tau_{ZX})^2]} \quad (3.14)$$

Entonces, el esfuerzo cortante octaédrico en una prueba de tensión uniaxial es:

$$\tau_{OctUni} = \frac{1}{3} \sqrt{2\sigma_f^2} = \frac{\sqrt{2}}{3} \sigma_f \quad (3.15)$$

Con esto, se define que el esfuerzo de falla ocurre cuando:

$$\sigma_f = \frac{1}{\sqrt{2}} \sqrt{(\sigma_1 - \sigma_2)^2 + (\sigma_2 - \sigma_3)^2 + (\sigma_3 - \sigma_1)^2 + 6[(\tau_{XY})^2 + (\tau_{YZ})^2 + (\tau_{ZX})^2]} \quad (3.16)$$

El valor de la izquierda es conocido también como el esfuerzo efectivo de Von Mises. Con este valor, por lo tanto, definimos nuestro factor de seguridad:


$$F.S. = \frac{\sigma_f}{\sigma_E} \quad (3.17)$$

Donde es el esfuerzo de cedencia.

## 3.2. Diseño de Válvulas de Mariposa

### 3.2.1. Definiciones y conceptos básicos

La válvula de mariposa es un componente dentro de la familia de las válvulas cuyo objetivo es regular el flujo de un fluido dentro de un conducto determinado. Esto se lleva a cabo mediante el aumento o reducción de la sección media de paso de una placa o "disco" (observado en la Figura 3.2), el cual gira sobre un eje. La disminución de dicha sección media aumenta la pérdida de carga local en la válvula y por consecuencia el flujo es reducido.


**Figura 3.2:** Partes básicas en una válvula de mariposa

Hay tres amplias familias de válvulas de mariposa: De cero compensación (*zero offset*), de compensación doble (*double offset*) y de compensación triple (*triple offset*):

- **Compensación cero:** También conocido como diseño concéntrico, es común en las válvulas de mariposa de servicio general con asiento "flexible" o "asiento de goma". Como se observa en la primera imagen de la Figura 3.3, el vástago y el disco están centrados en el asiento de la válvula, todos los cuales están centrados en el cuerpo de la válvula. El disco está en contacto constante con el asiento. Una ventaja de esta válvula es que, el medio que atraviesa la válvula no entrará en contacto con el cuerpo, ya que el asiento está construido como un manguito o cartucho dentro del cuerpo. Se utilizan en aplicaciones básicas y especiales de líquidos y gases de hasta 200 PSI y hasta 400 grados °F. La válvula de mariposa de compensación cero puede manejar productos químicos, revestimientos, alimentos, algunos sólidos y aplicaciones abrasivas.

- **Compensación doble:** La siguiente parte de la clasificación es conocida como la de "alto rendimiento". Los rasgos característicos de la válvula de mariposa estándar de alto rendimiento son: un vástago desplazado de la línea central del cuerpo, un disco relativamente grueso con una superficie de asiento definida como una sección esférica y un cuerpo con una pieza terminal extraíble para sostener un asiento que contiene un resorte circular. Esta válvula en especial tiene dos vástagos desplazados del centro, como se puede apreciar en la imagen central de la Figura 3.3. Esto crea una acción de leva durante el proceso de la aplicación. Hay dos desplazamientos principales: En el primero, el eje del eje está detrás de la línea central del punto de sellado del disco para asentar y en el segundo, el eje del eje es excéntrico al centro de la válvula/disco.
- **Compensación triple:** Con este tipo de válvula de alto rendimiento, como su nombre lo dice, hay tres compensaciones: dos se colocan en una posición similar a la válvula de mariposa de compensación doble, mientras que el tercer desplazamiento es la geometría de la superficie del asiento, creando un tipo de forma cónica del disco y el asiento. Este ángulo del cono, junto con las dos compensaciones del eje excéntrico, permite que el disco selle contra el asiento sin fricción, como se nota en la tercera imagen de la Figura 3.3. Las compensaciones triples se utilizan generalmente en aplicaciones similares a las válvulas de compuerta, donde se requiere un asiento de metal y se desea un cierre hermético y / o actuación de un cuarto de vuelta. La válvula de triple compensación se utiliza en industrias similares a la válvula de mariposa de doble compensación, pero en aplicaciones más exigentes.

**Figura 3.3:** Tipos de válvulas de mariposa: compensación cero, doble y triple, ordenadas de izquierda a derecha.



### 3.2.2. Materiales

La selección de un material para construir una parte de máquina o elemento estructural es una de las más importantes decisiones que debe tomar el diseñador. Por lo general, la decisión se toma antes de establecer las dimensiones del elemento. Después de seleccionar el proceso y el material para crear la geometría deseada (éstos no pueden estar separados), el diseñador puede proporcionar el elemento de manera virtual para evitar la pérdida de funcionalidad o que la probabilidad de dicha pérdida se mantenga a un nivel de riesgo aceptable [40].

**Figura 3.4:** Diferentes materiales utilizados en la fabricación de un avión



Para el sector aeroespacial, las notables características de rendimiento actuales son, en gran medida, fruto de los avances en el campo de los materiales de alto rendimiento y en las diferentes tecnologías de fabricación utilizadas en las distintas partes del avión, como se observa brevemente en la Figura 3.4. Para obtener incrementos continuos de rendimiento, los diseñadores están buscando constantemente materiales más ligeros, resistentes y duraderos.

Como bien se sabe, la manera más eficaz de reducir el peso del fuselaje y mejorar su rendimiento consiste en reducir la densidad y aumentar las propiedades mecánicas. Se ha estimado que las reducciones en la densidad del material son alrededor de 3 a 5 veces más eficaces en comparación con la mejora en propiedades mecánicas. Para las turbinas de motores a reacción, los avances en materiales han permitido significativos aumentos en temperaturas de operación, que se traducen en mayores niveles de empuje, aumentando considerablemente su rendimiento. [4].

### 3.2.3. Superaleaciones

Las superaleaciones o aleaciones de alto rendimiento presentan una excelente resistencia mecánica y resistencia a la fluencia en altas temperaturas, buena estabilidad superficial y elevada resistencia frente a la corrosión y oxidación.

Los elementos base de las superaleaciones empleadas en el sector aeroespacial son principalmente el níquel, cobalto y níquel-hierro. Las de níquel tienen un buen comportamiento hasta temperaturas de 1,000 °C y las de cobalto soportan aún mayores temperaturas sin degradarse sustancialmente [7]. Este tipo de materiales metálicos se utilizan, por ejemplo, en la fabricación de palas de turbina para secciones calientes de los motores a reacción, turborreactores y cámaras de combustión. Dentro de las superaleaciones a base de níquel y para aplicaciones típicas orientadas a este exigente sector podemos citar:



1. **Hastelloy D**: Fuerte, tenaz y extremadamente dura, lo que por el contrario es de difícil mecanización.
2. **Inconel**: Combina resistencia mecánica, a la corrosión y tenacidad, así como características del Níquel, con la resistencia a la oxidación a altas temperaturas típicas del Cromo. Resiste a la fatiga térmica sin hacerse frágil, por lo que se utiliza en la fabricación de escapes y calentadores de motores de avión.
3. **Nimonic 90**: Es la aleación básica para los motores a reacción por su resistencia a la fluencia, su alta tenacidad y estabilidad a altas temperaturas.

Las superaleaciones a base de cobalto mantienen su resistencia a temperaturas elevadas. Además de incorporar metales refractarios y carburos metálicos, contienen niveles elevados de Cromo, lo que aumenta la resistencia a la corrosión. Son más fáciles de soldar que otras superaleaciones y se forjan mejor. Se emplean para fabricar la estructura de la cámara de combustión de las turbinas y motores de cohetes, entre otros.

Las superaleaciones con elementos base como el aluminio y el cromo, se comportan bien frente a la oxidación y corrosión ya que se forma una capa de óxido cuando el metal está expuesto al oxígeno, encapsulando al material y protegiendo el resto de los componentes.

Las de base titanio resisten menos las altas temperaturas frente a las de Cobalto y Níquel. Sin embargo, en los últimos diez años se han realizado avances tecnológicos en el desarrollo de motores de turbinas para aeronaves y dirigibles utilizando estos materiales.

Las válvulas de mariposa de alto rendimiento tienden a estar disponibles en una amplia selección de materiales, incluidos aceros inoxidable y superaleaciones. Una válvula de mariposa de alto rendimiento hace el mismo trabajo que una válvula

de compuerta con una menor cantidad de material, por lo que, en el caso de las superaleaciones, a menudo hay un ahorro de costos considerable al usar una válvula de mariposa de alto rendimiento.

#### 3.2.4. Normativas de diseño y tolerancias en válvulas de mariposa

Las válvulas de mariposa se utilizan donde el espacio es limitado. A diferencia de las válvulas de compuerta, las válvulas de mariposa se pueden usar para regular el flujo, tanto en posición completamente abierta como completamente cerrada. La pérdida de presión a través de una válvula de mariposa es pequeña en comparación con la válvula de compuerta. La relación longitud-diámetro para este tipo de válvula es de aproximadamente de un tercio, comparada con la de compuerta. Es importante considerar las presiones diferenciales correspondientes a las posiciones de completa apertura y cierre de la válvula, ya que se necesita una gran fuerza del actuador para accionar la válvula en caso de un cambio abrupto de presión.

Dadas las situaciones anteriores y con el objetivo de regular el comportamiento y seguridad en el proceso de diseño, existen múltiples especificaciones para válvulas de mariposa, entre las mas importantes tenemos:

- **ASME B16.20** - Dimensiones cara a cara y de extremo a extremo de válvulas. (*Face to Face and End-to-End Dimensions of Valves*).
- **ASME F1098** - Especificación estándar para dimensiones envolventes para válvulas de mariposa. (*Standard Specification for Envelope Dimensions for Butterfly Valves*).
- **ASTM A522/A522M-01** - Especificación estándar para bridas, accesorios, válvulas y piezas de acero de aleación de níquel al 8 y 9% forjado o laminado

para servicio a baja temperatura. (*Standard Specification for Forged or Rolled 8 and 9 % Nickel Alloy Steel Flanges, Fittings, Valves, and Parts for Low-Temperature Service*).

- **ASTM B834** - Especificación estándar para pulvimetalurgia consolidada a presión Hierro-Níquel-Cromo-Molibdeno (UNS N08367) y Níquel-Cromo-Molibdeno-Columbio (Nb) (UNS N06625) Bridas, accesorios, válvulas y piezas de tubería de aleación. (*Standard Specification for Pressure Consolidated Powder Metallurgy Iron-Nickel-Chromium-Molybdenum (UNS N08367) and Nickel-Chromium-Molybdenum-Columbium (Nb) (UNS N06625) Alloy Pipe Flanges, Fittings, Valves, and Parts*).
- **AMS5383** - Aleación de níquel, resistente a la corrosión y al calor, fundición de inversión, 52.5Ni - 19Cr - 3.0Mo - 5.1Cb (Nb) - 0.90Ti - 0.60Al - 18Fe, homogeneización fundida al vacío y tratamiento térmico en solución. (*Nickel Alloy, Corrosion and Heat-Resistant, Investment Castings, 52.5Ni - 19Cr - 3.0Mo - 5.1Cb(Nb) - 0.90Ti - 0.60Al - 18Fe, Vacuum Melted Homogenization and Solution Heat Treated*)

### 3.2.5. Herramientas de Análisis


La discretización apropiada de un modelo en elementos finitos, provoca una mejor aproximación en la solución del mismo. El análisis por elementos finitos (FEA) es una herramienta que depende del número de elementos y el arreglo de estos para definir el modelo. La exactitud de la solución mejora cuando se incrementa el número de dichos elementos y por lo tanto, el requerimiento computacional. Para lograr una buena discretización se deben considerar los siguientes conceptos:

1. **Geometría física del dominio.** Se deben utilizar bastantes elementos en el modelo del dominio para tener exactitud en la solución. Cuando un

dominio curvo se discretiza usando elementos finitos se debe hacer con numero razonable de elementos; de otra manera estos generarán una discrepancia entre la geometría original y la discretización.

2. **Exactitud deseada.** Generalmente, usando más elementos se produce mayor exactitud en dichos resultados.
3. **Formulación de elementos.** Algunos elementos producen mayor exactitud que otros, es por ello que debe escogerse los más adecuados para llevar a cabo la discretización.
4. **Características especiales de la solución.** Requieren un gran número de elementos para capturar la exactitud, para con ellos tener altos gradientes en la solución.
5. **Interacción de elementos.** Los elementos son unidos por nodos. La solución a estos nodos son las variables primarias en el proceder del elemento finito. Esto es importante para crear mallas con elementos adyacentes, siempre de esquina a esquina.
6. **Simetría.** En muchos problemas prácticos, el dominio y las condiciones de frontera son simétricas, entonces se puede especificar simetría en el modelo y en la solución. Ejemplo de ello se observa en la Figura 3.5 donde es claro que existe un plano vertical (que pasa por la línea roja) de simetría. La importancia de reconocer la simetría implica obtener una ventaja en reducir el tamaño del modelo y con ello el sistema de ecuaciones a resolver.

**Figura 3.5:** Uso de FEA Software en diseño aeroespacial y simetría del objeto



### 3.3. Optimización de Diseño

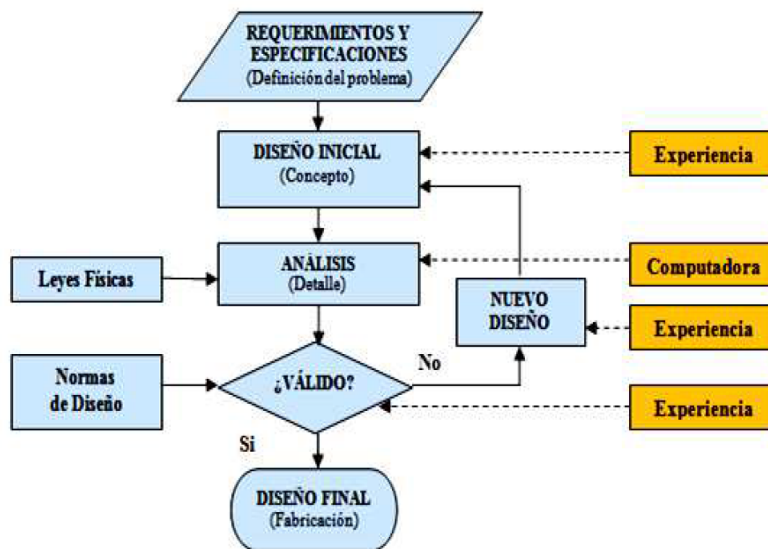
#### 3.3.1. Metodología de diseño Tradicional

En la actualidad, la mayoría de las técnicas que existen y se aplican durante las fases del proceso de diseño, utilizan de alguna manera, un procedimiento propio que está relacionado al razonamiento habitual de resolución de problemas. La metodología de diseño tradicional, como se puede observar en la Figura 3.6, se basa en la experiencia e intuición del diseñador como parte fundamental en cada una de las etapas del proceso de diseño, desde la fase de concepción de la idea hasta su fase de fabricación y mantenimiento[23].

Si bien, para generar ideas no se requiere ser un experto en el tema sobre el que se razona; hay fases de análisis de las ideas aportadas y de construcción de la solución que deben ser realizadas por especialistas. Entre las herramientas más conocidas para solucionar el problema de diseño, se encuentran técnicas propias de *Six sigma*

tales como: QFD, matriz de decisión, cartas morfológicas, entre otras, que son muy utilizadas dependiendo de la etapa del proceso en la que se encuentre el diseño[23].

**Figura 3.6:** Diagrama de diseño tradicional



### 3.3.2. Metodología de diseño Óptimo

Tradicionalmente, un diseño se realiza siguiendo un proceso en el cual, las modificaciones dependen en gran manera de la experiencia del diseñador, obteniéndose en algunos casos, soluciones ineficientes con alto costo en tiempo [46]. Las responsabilidades en el proceso de toma de decisiones son muchas, entre ellas:

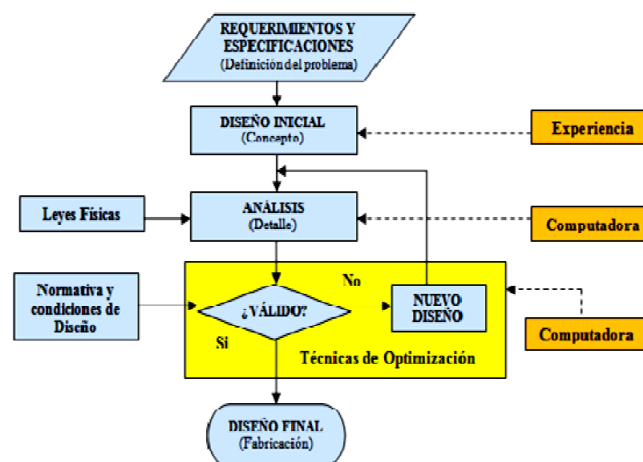
1. Definir las especificaciones del problema.
2. Elegir criterios de diseño adecuados.
3. Modelar y evaluar.
4. Realizar cálculos.
5. Interpretar y evaluar los resultados.

## 6. Elegir la mejor solución.

La última actividad en la lista anterior, depende fuertemente de la experiencia del diseñador. Normalmente, el diseñador no dispone de los parámetros o la capacidad de asegurar que la última propuesta de solución que obtenga sea la óptima, ya que le es físicamente imposible evaluar el espectro completo de posibles soluciones.

Es aquí, donde incluir la teoría de inteligencia artificial a la ingeniería de diseño, representa una opción atractiva para obtener una solución que cumpla con todas las condiciones y restricciones dadas de una manera rápida y eficaz. En la Figura 3.7, podemos observar el diagrama de flujo que ilustra el proceso.

**Figura 3.7:** Diagrama de diseño óptimo.



Así pues, el empleo de técnicas de optimización para automatizar el proceso de diseño son cada vez más habituales. La metodología de diseño óptimo permite analizar un mayor número de soluciones, lo cual le brinda al diseñador diferentes perspectivas de diseño del componente.

Asimismo, esta metodología permite considerar problemas complejos que cumplan con las exigencias estructurales actuales de forma que el resultado sea el óptimo.

## 3.4. Principios de Optimización Estructural

La optimización es un proceso a través del cual se busca obtener o determinar la mejor solución posible, de entre un grupo de resultados, que a su vez satisface las restricciones que presenta el sistema al cual se aplica [1]. Lo anterior significa matemáticamente: “La búsqueda del máximo o mínimo de una función objetivo”.

La optimización de un diseño incrementa el valor de un producto mejorando el rendimiento en su entorno operativo a menor costo de producción. Esto mediante la reducción de la cantidad de material utilizado para su fabricación y garantizando un tiempo de vida mucho mayor del producto bajo sus condiciones de operación. Al utilizar la optimización, el ingeniero de diseño incrementará los conocimientos sobre el comportamiento de su producto y obtendrá el mejor diseño.

Los métodos de optimización modernos están basados en técnicas heurísticas o metaheurísticas, ya que los métodos tradicionales son incapaces de abordar espacios de soluciones tan grandes, con la complejidad adicional de ser dispersos y no convexos. Estas técnicas, pueden estar afectadas por juicios del diseñador o por la capacidad de computo disponible en ese momento. A diferencia del método tradicional, estas técnicas modifican el planteamiento del problema, además de su geometría pero parten de una decisión condicionada que sin lugar a dudas, modifica el proceso de búsqueda.

### 3.4.1. Tipos de Optimización Estructural


En general se pueden distinguir tres tipos de optimización según las modificaciones realizadas a las estructuras:

**Optimización de Tamaño:** Consiste en discretizar una estructura preestablecida con elementos simples para encontrar las dimensiones óptimas. En los problemas



de optimización, las variables de diseño que pueden ser modificadas son: el área transversal del elemento, longitudes, espesores y radios, como se observa en la Figura 3.8. Estas se encuentran asociadas a las propiedades geométricas de las secciones transversales. La utilización principal de este tipo de optimización es en vigas.

**Figura 3.8:** Optimización de tamaño



**Optimización Topológica:** En estos problemas, no solamente se modifican dimensiones o posición de puntos característicos, sino también la existencia o no de elementos estructurales. Por ejemplo, en la optimización topológica de una estructura reticulada se obtiene como respuesta cuáles barras deben constituir la estructura y sus dimensiones, como se observa en la Figura 3.9.

**Figura 3.9:** Optimización topológica



**Optimización de forma:** Las variables de diseño definen la forma del componente. Por lo que al modificar parámetros geométricos del modelo de las variables del diseño original, se mejora el comportamiento mecánico. Por ejemplo: para reducir altas concentraciones de esfuerzos que normalmente aparecen en las esquinas de las piezas o en aquellas zonas donde ocurren cambios bruscos en la forma de la sección (Figura 3.10). De igual manera, reducciones de material, modificaciones de forma en su totalidad, etc.

**Figura 3.10:** Optimización de forma.

La industria aeroespacial y automotriz aplican la optimización del tamaño y forma al diseño de estructuras y elementos mecánicos.

### 3.4.2. Modelos computacionales heurísticos

El conocimiento heurístico es un tipo especial de conocimiento utilizado para resolver problemas complejos. La palabra proviene del griego *Heuriskein* que significa descubrir. Como tal, la Heurística es la ciencia que estudia los procesos de decisión respecto a un campo de conocimiento concreto, como lo es el algoritmo para el área de la computación.


Por lo general, cuando se presentan problemas complejos de interés práctico, se plantean algoritmos que aunque no ofrecen el resultado óptimo, se acercan a una aproximación razonable. Estos algoritmos están basados en conocimientos heurísticos y por lo tanto se conocen como algoritmos heurísticos.

#### 3.4.2.1 Redes neuronales

Desde su nacimiento en la década de los 50's, las llamadas redes neuronales artificiales han sido identificadas como una de las áreas más prometedoras de la ciencia dentro del campo del aprendizaje profundo. Las redes neuronales artificiales son modelos computacionales inspirados en el funcionamiento del cerebro humano [34]. La principal característica de las redes neuronales es su capacidad de “aprender” durante la fase de entrenamiento. Después cada neurona aplica el conocimiento adquirido para predecir y resolver nuevas situaciones.

Cada red esta formada por un conjunto de nodos conocidos como neuronas artificiales que están conectadas y transmiten señales entre sí. Estas señales se transmiten desde la entrada hasta generar una salida, como se puede mostrar en el ejemplo de la Figura 3.11.

**Figura 3.11:** Ejemplo básico de una red neuronal.



Las neuronas de la red están a su vez agrupadas en capas que forman la red neuronal. Cada una de las neuronas de la red posee a su vez un peso (valor numérico), con el que modifica la entrada recibida. Asimismo, los nuevos pesos obtenidos salen de las neuronas y continúan su camino por la red. Como se mencionó anteriormente, para conseguir que una red neuronal realice las funciones deseadas, es necesario entrenarla. El entrenamiento de una red neuronal se realiza modificando los pesos de las neuronas para que consiga extraer los resultados deseados.

Los modelos de redes neuronales son modelos matemáticos que define cualquier función  $f(x) = y$ . Estos generalmente están relacionados a alguna regla o algoritmo de aprendizaje particular.

El término red se refiere a las interconexiones entre las distintas neuronas y el conjunto de neuronas en un mismo nivel se conocen como “capa”. Mientras más capas tenga una red, mas compleja será. Una red básica como la de la figura 3.11 tiene solo 3 capas: La primera contiene las neuronas de entrada, las cuales envían

los datos iniciales a la segunda capa a través de la llamada sinapsis (donde se almacenan los pesos) y a su vez, éstas envían sus datos por medio de más sinapsis a una tercera capa de salida.

Hay 3 parámetros que generalmente definen una red neuronal:

- La sinapsis, que es la manera en la cual las diferentes capas de las neuronas se conectan, es decir, el patrón de interconexión entre las capas.
- El aprendizaje es el proceso por el cual los pesos de las interconexiones serán actualizados. Existen diferentes métodos de aprendizaje, entre los más importantes tenemos: el aprendizaje supervisado, el no supervisado y el aprendizaje por refuerzo.
- La respectiva función de activación, que tiene como objetivo limitar el rango de salida de las neuronas. Esto sirve para proporcionar una transición suave para los valores de entrada y salida de los pesos.

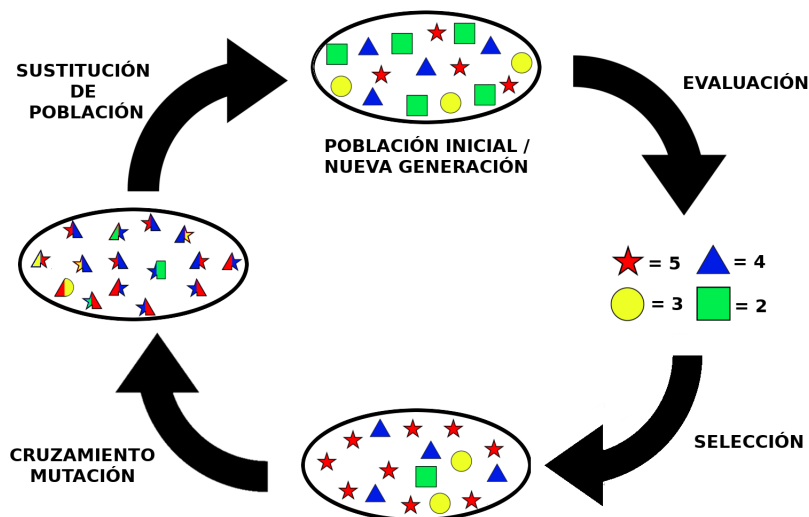
#### **3.4.2.2 Algoritmos Genéticos**

Otro de los modelos heurísticos computacionales más conocidos y utilizados como parte de métodos de optimización estructural son los algoritmos genéticos. Esto se debe a la gran versatilidad y adaptabilidad que poseen, lo cual les permite trabajar a distintas restricciones impuestas.

El principio básico está basado en el proceso genético de los organismos vivos. Básicamente, el mecanismo de selección utiliza el principio de la teoría evolutiva darwiniana, en el cual solo los individuos más aptos son quienes sobreviven, al adaptarse más fácilmente a los cambios que se producen en su entorno. De manera más técnica, se representan mediante una función matemática que toma como entradas a los individuos ejemplares y retorna como salidas a los más aptos, para

generar descendencia. Tradicionalmente, se genera un ciclo iterativo en el cual, la nueva generación reemplaza a la anterior una cantidad de veces determinada como propio parámetro de diseño. En la Figura 3.12, podemos ver como se lleva a cabo el ciclo típico dentro de un algoritmo genético básico.

**Figura 3.12:** Ejemplo básico del ciclo del algoritmo genético.



Los Algoritmos Genéticos difieren de los métodos tradicionales de optimización de varias formas:

1. Utilizan funciones objetivo para determinar la aptitud del individuo a evaluar.
2. Los Algoritmos Genéticos son ciegos.
3. No trabajan con las variables de diseño, sino con una codificación.
4. Utilizan un conjunto de puntos del dominio, en contraposición con los métodos tradicionales que se basan en un único punto. Esto se traduce en, que para cada iteración, los Algoritmos Genéticos procesan y evalúan un determinado número de diseños.

5. Utilizan reglas u operadores estocásticos en lugar de las tradicionales reglas determinísticas.

Dentro de su estructura tenemos una población de posibles soluciones que están formadas por individuos o fenotipos que, a su vez, son soluciones particulares. Cada solución candidata tiene un conjunto de características, también conocidas como cromosomas o genotipos que son las que pueden ser alteradas por el algoritmo (por medio de operadores genéticos). Estas soluciones son representadas en la mayoría de los casos como cadenas binarias o conjuntos de valores reales.

Al pasar de una generación a otra ocurre la llamada "evolución". Este proceso iterativo es generado por una población representativa generada al azar. En cada una de estas generaciones se evalúa la aptitud (fitness) para cada individuo de la población actual. La función fitness se representa de manera matemática como el valor de la función objetivo en el problema de optimización.

Existe la certeza matemática de que el algoritmo es capaz de obtener siempre un óptimo global si no existe una limitación temporal en el cálculo. Independientemente del problema planteado, los componentes principales son los siguientes [6]:

1. Una representación de soluciones potenciales al problema.
2. Un método para crear la población inicial de posibles soluciones.
3. Una función de evaluación que califica las soluciones en base a su *fitness*.
4. Operadores genéticos que alteran la composición de los hijos y, por consiguiente, de las siguientes generaciones.

## 4. Formulación y desarrollo del problema

### 4.1. Metodología general

Como primera instancia, en la Figura 4.1 muestra el diagrama en el cual se representa de manera gráfica la metodología de optimización realizada en éste trabajo.

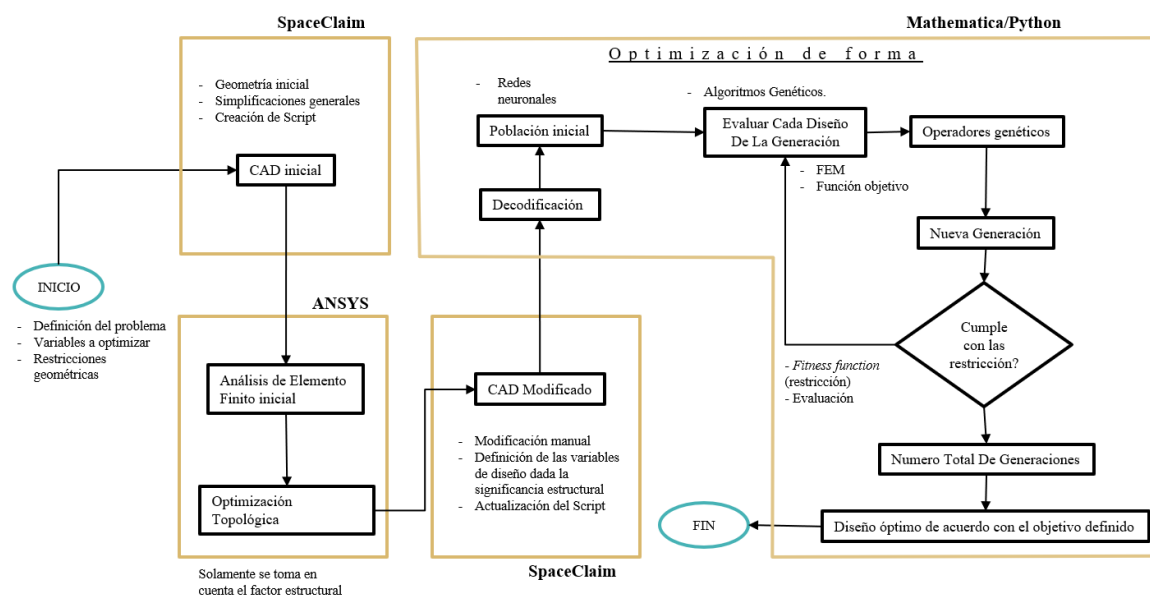


Figura 4.1: Mapa de Proceso

La metodología de diseño óptimo presentada en la Figura 4.1, involucra estrategias heurísticas las cuales provocan una convergencia entre las distintas posibles soluciones. La evolución se da hacia la solución óptima y responde a las condiciones que se encuentra sometido nuestro modelo conforme transcurre el tiempo. Los pasos básicos del proceso se detallan a continuación:

Inicio:

- Definición del componente a optimizar y restricciones de diseño iniciales.

Etapa 1:

- Simplificación de geometría y creación de Script de optimización.

Etapa 2:

- Ejecución de análisis de elemento finito para conocer comportamiento actual del componente.
- Primera optimización (topológica). Esta se lleva a cabo con el tensor de esfuerzos usando el resultado del análisis anteriormente realizado.

Etapa 3:

- Definición de las variables de diseño finales y actualización del Script.

Etapa 4:

- Se genera una primera población, la cual debe estar bien distribuida en el espacio de diseño. Esto se lleva a cabo con la ayuda de Redes neuronales (RN).
- Optimización multiobjetivo con el uso de algoritmos genéticos.
  1. Evaluación de la población con la función multiobjetivo y análisis de sensibilidad.
  2. Elección de los mejores candidatos de la generación. Estos se convierten en los padres, a los cuales se les aplican operadores de cruce y mutación.
  3. Creación de una nueva generación.
  4. Evaluación de la nueva generación. Este paso se realiza las veces que sea necesario o el número de veces definido con anterioridad.



- Obtención de una población final con respecto al criterio de paro, en la cual se elige al candidato más apto de entre todas las generaciones evaluadas.

En las siguientes páginas se describe a detalle cada uno de los pasos de la metodología presentada.

## 4.2. Elección del componente

Dada la complicación y tiempo requerido para plantear y analizar un subsistema y/o estructura compleja en una aeronave, se optó por elegir un componente genérico adecuado para el caso de estudio. Como bien se mencionó anteriormente, optar por mejoras en sistemas y componentes más sencillos, pero con presencia constante y alto volumen dentro de la aeronave es una opción realista que se ajusta a las necesidades a corto plazo que la industria requiere.

Dentro de todos los componentes que fueron candidatos para el caso de estudio, se evaluaron 3 características:


1. **Complejidad del componente:** Analiza la facilidad de definir las variables de diseño y zonas de optimización.
2. **Utilización del componente en otros subsistemas:** Evalúa que tanta presencia tiene el tipo de componente dentro de la aeronave.
3. **Versatilidad de adaptación de resultados:** Evalúa el impacto potencial de la optimización hacia otros componentes similares y/o con características cercanas.

La elección de la válvula de mariposa es de interés, dada la importancia y dinamismo que presenta dentro de distintos subsistemas. Además, investigaciones anteriores sobre éste tipo de válvula plantean métodos que pueden ser comparables y funcionar como punto de partida para problemas de optimización.

### 4.3. Condiciones Iniciales

Para definir las condiciones iniciales del componente, primeramente se define la posición del mismo dentro de un sistema mayor. La válvula en cuestión es parte de un actuador situado dentro del sistema de presurización de la aeronave. Como se ve en la Figura 4.2 (a), el actuador en cuestión controla el eje de la válvula de mariposa y asimismo su movimiento.

Dentro del ensamble del actuador tenemos el ducto principal mostrado en la figura 4.2 (b), que es precisamente por donde el aire fluye a lo largo del sistema y con el cual nuestra válvula hace contacto y restringe el paso del aire cuando ésta cerrada.



**Figura 4.2:** Detalle del Ensamble.

Finalmente tenemos el componente en cuestión, el disco de la válvula de mariposa, el cual funciona por medio de un pasador que actúa como eje y su función principal es permitir o restringir el paso del aire por el ducto. El ejemplo visual del disco lo podemos ver en la Figura 4.2 (c).

### 4.3.1. Material

Con respecto al resto de los detalles de operación, tenemos que el disco utilizará la aleación INCONEL 718 como material para ser analizado. La aleación 718 es un material fundido al vacío, endurecido por precipitación. En el Cuadro 4.1 se muestran sus propiedades principales.

Propiedad	Sistema Inglés	Sistema Internacional
Esfuerzo último	120 KSI	827.4 MPA
Límite de Fluencia	105 KSI	723.94 MPA
Modulo de Elasticidad (E)	29.4 103 KSI	202.70 GPA
Modulo de Rigidez (G)	11.4 103 KSI	78.60 GPA
Densidad	.297 lb/in <sup>3</sup>	8.220 g/cm <sup>3</sup>

**Cuadro 4.1:** Propiedades del INCONEL 718.

Es una aleación de base de níquel. Es moldeable y tiene buena resistencia al agrietamiento por envejecimiento. Los tratamientos térmicos mas habituales se realizan a temperaturas promedio de entre 1700 y 1800 °F por un periodo de una hora y en reposo a 1150 °F durante 17 horas, aproximadamente. Dependiendo de la elección de dichos tratamientos (dados en su mayoría por AMS2774), se logra alta resistencia a la fluencia y ruptura por tensión hasta 1300 °F o alta resistencia a temperaturas criogénicas.

### 4.3.2. Condiciones de operación

A continuación se describirán las restricciones iniciales con las cuales se realizaron los análisis estructurales del componente. Cabe destacar que estas consideraciones se obtuvieron de manuales de operación disponibles de manera gratuita en la red, por lo cual son valores genéricos muy cercanos a los reales. En el cuadro 4.2 se muestran los valores típicos de operación.

Propiedad	Sistema Inglés	Sistema Internacional
Temperatura de entrada máxima	1274 °F	690 °C
Presión de entrada máxima	548 PSIG	3.77 MPA
Presión media	1495 PSIG	10.30 MPA


**Cuadro 4.2:** Condiciones de temperatura y presión típica de la válvula de mariposa.

Propiedades adicionales se listan a continuación:

- Temperatura ambiente típica de operación: Se define en un rango de valores que van del -55 a 390 °C.
- Números de ciclos de vida: Después de analizar varios ejemplos de válvulas con las mismas condiciones y según datos de fabricantes, se determinó que los ciclos de vida para la válvula en cuestión serán 150 000.
- Criterios de aceptación: Margen de seguridad=0.99.

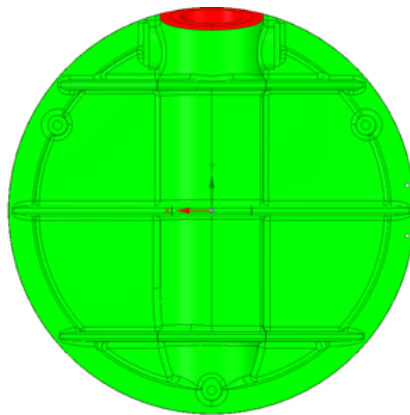
### 4.3.3. Condiciones de Frontera

A partir de éste punto, todo el desarrollo y análisis se hace solo en el cuerpo de la válvula, es decir, el disco. Así que después de definir las condiciones de operación del componente, se procede a identificar los límites de frontera de dicho disco para terminar de definir los parámetros del análisis estructural. En la Figura 4.3 podemos ver como hay un pasador que atraviesa de manera perpendicular el eje del disco con el propósito de ajustarlo al ducto con el que va conectado y de esa manera asegurar que no haya desplazamientos indebidos dentro del ensamble.




**Figura 4.3:** Detalle de restricción en pasador.

La Figura 4.4 nos muestra la restricción que se genera entre el pasador del eje principal que va conectado al ducto, de manera que limita el movimiento del disco en dos posiciones: Cuando la válvula esta abierta y deja pasar flujo ( $90^\circ$ ) y cuando esta cerrada ( $0^\circ$ ).



**Figura 4.4:** Detalle de restricción en eje.

Por último, tenemos la restricción que limita el espacio de la válvula dentro del ducto, representado en la Figura 4.5, con esto, podemos notar que el disco siempre tiene que estar en contacto con el ducto para de esa manera regular y/o sellar el paso del aire.



**Figura 4.5:** Detalle de restricción en diámetro externo.


#### 4.4. Simplificación de Modelo en CAD y definición de las variables de diseño

Para facilitar el futuro análisis y con el propósito de eliminar detalles del componente que podrían ser causa de ruido (por ejemplo, radios agregados para facilitar la manufactura, terminaciones estéticas, etc), después de identificar las condiciones de frontera, se procedió a re-modelar el componente desde cero, manteniendo únicamente la geometría básica.

Para ello fue necesario definir las diferentes zonas que forman el modelo del disco, de ésta forma es mas sencillo organizar la optimización por secciones específicas. Tomando en cuenta las restricciones de diseño mostradas en la sección de condiciones de frontera, podemos descartar por adelantado algunas de dichas zonas, de modo que se reduce la cantidad de variables de diseño de manera significativa. A continuación se listan las mismas y se muestran en la figura 4.6:


- ***C1***: Distancia entre Costilla 1 y 2
- ***C2***: Distancia entre Costilla 2 y 3
- ***T1***: Ancho o *Thickness* de la costilla
- ***DM***: Diámetro Mayor del Eje

- *DC*: Diseño de la costilla: Depende de la forma fila de la misma, tomando como base el trapecio del diseño inicial.




**Figura 4.6:** Detalle de las variables de diseño.

Como se observa en la Figura 4.7, *DC* no es una sola dimensión, ya que define la forma de cada una de las costillas. Dado el alcance del proyecto y con el objetivo de simplificar el resultado, se tomó la decisión de mantener el diseño básico de cada una de las costillas en estado inicial, es decir, con la forma básica de un trapecoide.



**Figura 4.7:** Simplificación de DC.

Después de realizar la división anteriormente explicada, se procedió a re-modelar el disco, siendo el resultado el mostrado en la Figura ??, donde se observa como las zonas han sido marcadas de manera clara para ayudar a identificar fácilmente las diferentes áreas a modificar.




**Figura 4.8:** División del modelo CAD para simplificación.

La zona en color verde esta dada por el disco, la zona en azul muestra el eje principal. En amarillo tenemos delimitada la zona del pasador de ajuste con el eje y, por ultimo, en color morado podemos ver las 3 costillas que funcionan como soporte estructural para la geometría del disco.


A continuación se muestra la Figura 4.9, en la cual tenemos las vistas del modelo original, modelado en un CAD externo y con aún todos los radios y algunos acabados que podrían intervenir en el proceso de optimización.





**Figura 4.9:** Vistas de modelo original: Vista isométrica, frontal y lateral.

En cambio, en la figura 4.10, podemos ver el resultado a detalle de la simplificación del disco después de su modelado desde cero.



**Figura 4.10:** Vistas de modelo Simplificado: Vista isométrica, frontal y lateral.

## 4.5. Script y Parametrización

Para llegar a nuestro objetivo de optimización se necesitan múltiples iteraciones, en las cuales la geometría inicial se va modificando lentamente. Este proceso de

optimización estructural sigue típicamente la vía paramétrica, donde la forma y la topología de la estructura son definidas por un grupo de parámetros, y éstos son ajustados para cumplir con la función de diseño deseada.

Ya que ciertamente es tardado e impráctico realizar modificaciones manuales al CAD en cada una de dichas iteraciones, es necesario automatizar lo mas posible el proceso. Para ello se recurrió a la creación de un *Script* dentro del software de CAD *SpaceClaim*. Este llamado *Script* nos permite crear y correr una serie de funciones y comandos realizados por medio del lenguaje Python para crear nuestro CAD repetidas veces sin necesidad de intervenir.

El Script fue crucial para disminuir considerablemente el tiempo de creación de cada una de las iteraciones de CAD a evaluar por los algoritmos genéticos. Se modeló el disco teniendo cuidado de definirlo de la manera mas sencilla posible, para evitar tener un código que gastara tiempo de procesamiento innecesario en operaciones triviales.

Cada una de las variables de diseño se convirtió en un parámetro sujeto a un valor específico, dependiendo si fuera un valor a modificar o una constante dentro de la geometría.

## 4.6. Análisis de Elemento Finito en condiciones iniciales

Después de la simplificación inicial y definición del Script básico, se procedió a realizar el análisis de elemento finito en condiciones iniciales. Este análisis, además de darnos información acerca del estado actual del componente, nos provee los valores de los esfuerzos equivalentes en cada nodo de la válvula.

Primeramente, se realizó un análisis de sensibilidad de malla para encontrar el

tiempo de procesamiento óptimo para el algoritmo, tomando en cuenta 10 diferentes tamaños de elemento. Los resultados se muestran en la tabla 4.3:

Von Misses Promedio (MPa)	Numero de Elementos	Tiempo (s)	tamaño elemento (in)	Numero de iteraciones <sup>1</sup>
64.049	85709	5m 42s	0.05	23
62.091	49470	2m 5s	0.065	16
63.052	31739	41 s	0.08	12
62.3	21496	33 s	0.095	11
62.18	19428	25.36 s	0.1	10
59.796	14843	22.82 s	0.115	10
61.182	10412	15.68 s	0.13	9
59.097	8269	7 s	0.145	9
61.246	7472	4 s	0.15	9


**Cuadro 4.3:** Análisis de Sensibilidad de Malla

Tomando en cuenta el tiempo de procesamiento y dada la cantidad de iteraciones<sup>1</sup> que se tendrían que llevar a cabo, se eligió el tamaño de elemento .08 in como el idóneo para el proyecto, dado que el tiempo de procesamiento es dos veces menor que .065 in y la diferencia en resultados es menor a un 1 MPa en promedio.



Así bien, utilizando las condiciones de frontera anteriormente planteadas, se realizó un análisis estructural usando la condición de simetría geométrica. En la Figura 4.11 podemos observar como se aplican las restricciones de soporte fijo y la presión correspondiente, mencionada anteriormente en la Sección 4.3.3.

---

<sup>1</sup>valores de referencia

**Figura 4.11:** Condiciones de Frontera en ANSYS.

Las Figuras 4.12 y 4.13 muestran los resultados del análisis. En el caso de los resultados es importante describir la zona donde se encuentran la deformación total, esfuerzo máximo y equivalente (Von mises).

**Figura 4.12:** Resultados de Análisis inicial 1.**Figura 4.13:** Resultados de análisis inicial 2.

La parte crucial para el proyecto, además de conocer el estado inicial del componente, es el archivo de texto que se genera del análisis, ya que éste contiene la representación numérica de cada nodo, elemento y su respectivo valor en 3 dimensiones por medio de los esfuerzos en cada uno de los anteriores. Este archivo de texto se manda a llamar dentro de un "Master Script" que se creó en el programa *Wolfram Mathematica* y contiene todas las instrucciones para el programa de optimización estructural. Mas detalles serán descritos en las siguientes secciones.

## 4.7. Optimización Topológica

Después del análisis de elementos finitos y dentro de la misma interfase de ANSYS, se procedió a realizar una optimización topológica, la cual será realizada una sola vez con el objetivo de identificar las zonas geométricas mas sensibles a cambio.


La estructura óptima se logra cuando se alcanza una convergencia en los resultados, es decir, cuando ya no se pueda remover más material de la estructura y no viole las condiciones impuestas. En éste caso, el proceso se realizó con ayuda del software de ANSYS con su módulo de *Topology optimization*.

Siguiendo las condiciones impuestas por la operación del componente y el problema a tratar, el proceso de optimización topológica requiere que se definan 3 entradas:

- El volumen: es la variable a resolver por el software, dado que el objetivo es obtener un componente más ligero que el actual.
- La función objetivo: es impuesta por el proceso, en este caso es la obtención del valor mínimo de la variable de diseño.
- Las restricciones: son dadas por el proceso definidas en función del material a utilizar y son los valores que no se deben sobrepasar, tales como el valor del esfuerzo de cedencia del material.

Como se puede observar en la Figura 4.14, la principal zona de optimización está dada en el área del eje principal, sin embargo es una sección donde el cambio no es aceptable pues de éste tamaño depende la conexión con el actuador y subsecuentes sub-ensambles. La otra zona de cambio que se identifica es la tercera costilla, la cual se muestra consumida hasta casi la mitad de la geometría actual. Tomando en cuenta el impacto en alcance y en cantidad de remoción de material, en este punto se decidió enfocar el esfuerzo del proyecto en la re-definición de las costillas. De ésta manera, el problema de optimización se reduce a un entorno en dos dimensiones.

**Figura 4.14:** Resultado de Optimización Topológica.



## 4.8. Proceso de Optimización y Codificación

El objetivo del proyecto es obtener el diseño óptimo, es decir, un conjunto de valores de las variables de diseño que alcance a la función objetivo y cumpla una serie de restricciones de las que dependen dichas variables. Dentro de los algoritmos genéticos (GA), la función objetivo es equivalente a la función de aptitud o *fitness*.

Esta función constituye el núcleo central de los Algoritmos Genéticos y es una representación del problema a resolver donde se cuantifica adaptabilidad de cada solución (individuo).

Así pues, el proceso de optimización de forma, al igual que en el caso de la optimización topológica, se define primeramente como una función de minimización en la cual el objetivo principal es la *remoción* de material.

Minimizar  $f(x)$ , dado que:

$$h_j(\mathbf{x}) = 0 \quad j = 1, 2, \dots m_i \quad (4.1)$$

$$g_j(\mathbf{x}) = 0 \quad j = 1, 2, \dots m_d \quad (4.2)$$

$$x_i^{LI} \leq x_i \leq x_i^{LS} \quad i = 1, 2, \dots n \quad (4.3)$$

En ésta función,  $x$  representa el vector que define la variable de diseño a modificar,  $f(x)$  es la función objetivo,  $h_j(x)$  es restricción de diseño de igualdad  $j$ ,  $g_j(x)$  es restricción de diseño de desigualdad  $j$ ,  $m_i$  y  $m_d$  son el numero de restricciones de igualdad y de desigualdad, respectivamente;  $n$  es el número de variables de diseño y  $x_i^{LI}$  y  $x_i^{LS}$  son los límites inferiores y superiores, respectivamente, de la variable  $x_i$ .

Ahora bien, de manera mas específica, nuestro proceso de optimización de forma se define:

1. Se crea una población inicial con ayuda de Redes Neuronales.
2. Se evalúa cada individuo de la población con respecto a su función de fitness.

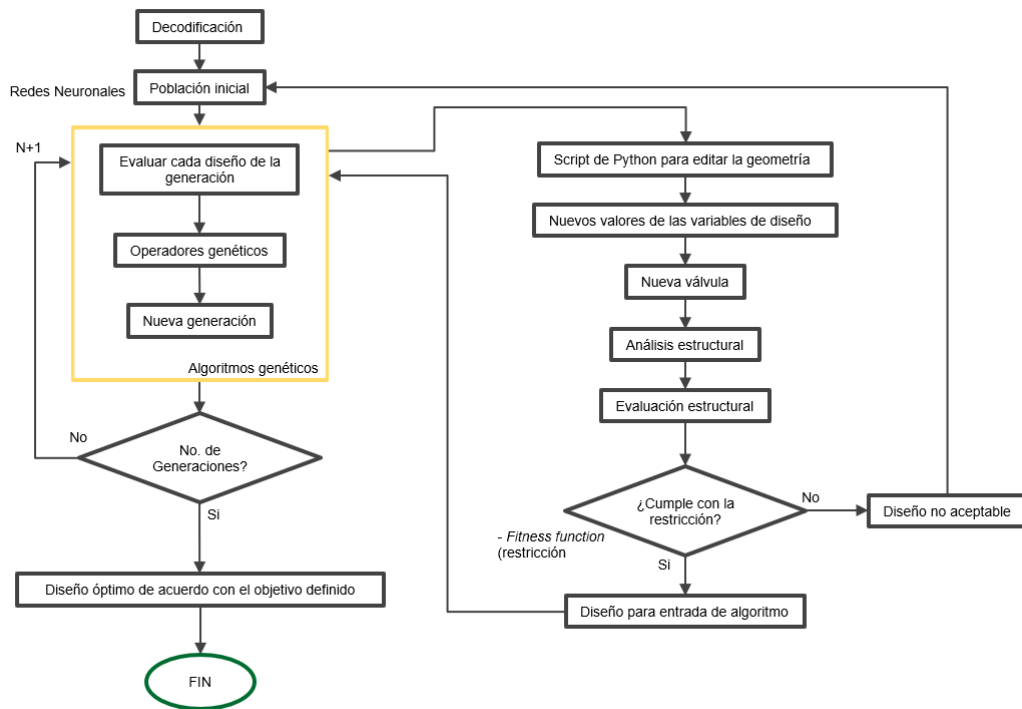
En éste punto:

- a) Se obtienen valores nuevos para cada variable de diseño.
- b) Se modifica la frontera de la geometría por medio de las curvas NURBS.



- c)* Se crea un CAD para cada individuo.
  - d)* Se somete el individuo a FEA.
  - e)* Se obtiene el valor de esfuerzo equivalente y deformación de cada nodo de frontera de la geometría.
  - f)* Se separan los valores aplicados a las costillas.
  - g)* Se codifica dentro de una serie de vectores que representan al componente algorítmicamente.
3. Se realizan los operadores de cruce y mutación.
  4. Se crea una nueva generación.
  5. Esto marca el inicio del siguiente ciclo y se continúa hasta llegar al número de generaciones determinadas.
  6. Se evalúa la generación final y elección del candidato idóneo.

Del análisis inicial de FEA se obtienen los valores de los esfuerzos equivalentes en cada nodo de la válvula para cada una de las costillas. Dicha representación está dada por una serie de vectores de caracteres reales que constituyen matemáticamente tanto su topología como sus propiedades estructurales. Estos vectores representan el componente y cada conjunto de ellos constituye un individuo. En la figura 4.15, podemos observar de manera más clara el mapa del proceso de manera secuencial.

**Figura 4.15:** Mapa general de Optimización de Forma


## 4.9. Manipulación geométrica por medio de NURBS

La idea básica detrás de generar un modelo es pasar el concepto geométrico del mismo a un entorno computacional. Esto se logra a través de la codificación de dicha geometría en términos algebraicos y subsecuente adición a un algoritmo para darle solución.

Una superficie B-spline no uniforme racional (NURBS, por sus siglas en inglés) es la manera más flexible de representar matemáticamente la superficie en un modelo. Una NURBS es fácil de modificar debido a que cada polo de su red de control afecta una parte limitada de la forma poligonal de la superficie. La red de control


es análoga al polígono de control de una NURBS.

**Figura 4.16:** Representación básica de la costilla con NURBS.



En la Figura 4.16, podemos observar la definición básica de la costilla en un entorno 2D. Recordemos que las NURBS involucran un cociente de sumas por cada punto de control. Esto quiere decir que cada punto observado en la Figura 4.17 tiene puntos de control que modifican la frontera de la geometría. La ventaja principal de este tipo de curvas es que se puede realizar una representación mas fiel de ciertas formas y regular con mas exactitud su funcionamiento.

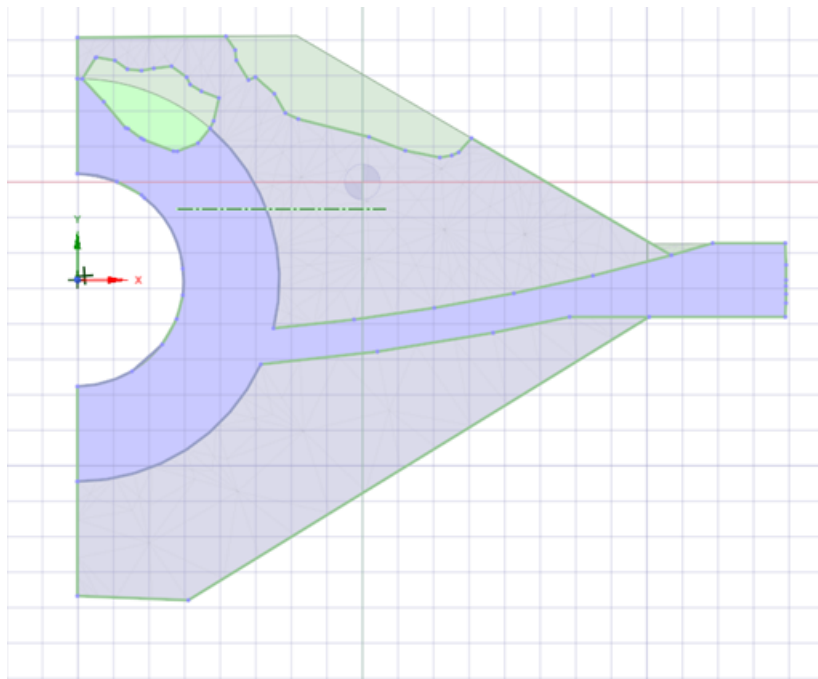
**Figura 4.17:** Representación básica de la costilla con puntos.



Se muestra como referencia el modelo de optimización topológica en la Figura 4.18 para ejemplificar como se importan los valores al software de CAD. Con la ayuda

del script que genera el modelo simplificado de la válvula, también se calcula la dirección de los desplazamientos de los puntos de control. Estos están sujetos a cumplir con las condiciones planteadas por la función fitness.

**Figura 4.18:** Importación de modelo de Optimización a CAD para referencia



## 4.10. Definición de requerimientos y elección de Red Neuronal


Los algoritmos genéticos necesitan una primera generación con una buena distribución sobre el espacio de diseño antes de iniciar el proceso de optimización. La ventaja de proporcionar al GA una población distribuida es que, si la población inicial es buena, la posibilidad de encontrar una solución aceptable es mayor. Mientras más complejo sea el problema de optimización, el factor de diversificación es más importante.

La red neuronal (NN) nos ayuda a generar esta población inicial, dadas sus conocidas características de diversificación. Las redes de neuronales artificiales emulando a las biológicas tienen un mecanismo de aprendizaje, que se basa fundamentalmente en el criterio de prueba y error [8]. Esto quiere decir que se aplica una función para determinada entrada y si no se obtiene la salida buscada se vuelve a probar la red pero variando los pesos (tasa de variación). Si nuevamente no se obtiene la salida esperada se vuelve a probar y así sucesivamente, hasta obtener la salida buscada. Después que se logra la salida buscada, termina la etapa de aprendizaje de la red y ahora se puede dar a la red una entrada cualquiera. En este punto la red opera y obtiene la salida respectiva según las funciones objetivo de la red entrenada.

En resumen, podemos dividir el proceso de la red neuronal en dos etapas:

1. Entrenamiento de la red (búsqueda de la salida esperada).
2. Aplicación de la red entrenada a cualquier entrada y obteniendo la respectiva salida.

Dentro del tipo de red neuronal, se clasifican dependiendo de su arquitectura y funciones. En cuyo caso se elige una NN supervisada. El modelo más utilizado en la actualidad es la red *Backpropagation*. Su nombre es la abreviatura de “propagación hacia atrás de errores”. Este modelo para el aprendizaje supervisado de redes neuronales artificiales se realiza mediante el descenso de gradientes. Dada una NN y una función de error, el método calcula el gradiente de la función de error con respecto a los pesos de la NN. Ejemplo de este tipo de red se muestra en la Figura 4.19.

**Figura 4.19:** Ejemplo de Red Backpropagation, tomado de [34].

La red neuronal específica utilizada en el proyecto es pre-establecida, dado que su función está limitada a la creación de la primera generación. La Red Neuronal aquí utilizada es la descrita en el libro *Neural Network and Deep Learning* de Michael Nielsen, licenciada por el MIT. A continuación se presentan las características principales y entradas de la red:

- Numero de capas: 2
- Función de activación de densidad de capa: elu
- Optimizador de la red: adamax

Los valores de codificación de la NN son los mismos que serán después utilizados por los GA. Es importante mencionar que la función objetivo se comparte entre los dos métodos heurísticos.

#### 4.10.1. Algoritmos genéticos

Como bien se mencionó anteriormente, los Algoritmos Genéticos (GA), se basan en la genética y la selección natural. Existe la certeza matemática de que el algoritmo

es capaz de obtener siempre un óptimo global. La principal cualidad de este tipo de algoritmo es su robustez y el equilibrio entre eficiencia y eficacia en la determinación de los puntos óptimos.

En términos generales podemos definir un algoritmo genético de la siguiente manera: Dado el espacio de individuos  $I$  que pertenecen al entorno real, se genera inicialmente la población  $\chi$  (vector población de tamaño  $v$ ), formada por los individuos  $\{a_1, \dots, a_v\}$  que será evaluada por una función  $\phi$  que asigna a cada individuo una aptitud. En base a ésta, se seleccionará mediante determinadas reglas de operadores de selección: un conjunto de padres  $\{\bar{\chi}=\bar{a}_1, \dots, \bar{a}_v\}$ , los cuales engendrarán un conjunto de hijos  $\{\chi''=a''_1, \dots, a''_v\}$ , los cuales tras ser evaluados por la función  $\phi$  formarán la población  $\chi$  de la siguiente generación. Así, éste proceso se repite hasta que se cumpla con alguna condición de terminación.

En general el proceso evolutivo requiere de una llamada relación de rechazo, en la cual necesitamos dos parámetros: el primero es una tasa de rechazo (RR) y la segunda es una tasa de adición (ER). Para cada individuo de la generación:

1. Una malla es generada.
2. Se aplican cargas y condiciones de frontera.
3. Se eliminan los elementos del modelo haciendo una comparación entre el esfuerzo en cada punto y el esfuerzo total de la estructura, a través del criterio de Von Misses.

Al final de cada análisis estructural, los elementos que satisfacen la condición siguiente son borrados del modelo:

$$\frac{\sigma_0}{\sigma_{max}} < RR \quad (4.4)$$

Donde:  $RR$  es la tasa de rechazo (Rejection Rate). El ciclo de análisis y remoción de elementos se repite dependiendo de número de generaciones. Los modelos que se encuentran sometidos a un sistema de carga, tendrán una región o zona modificable, en donde los nodos de esta región cumplan con alguna de las siguientes condiciones:

$$\sigma_i \leq TR * \sigma_R \quad (4.5)$$

$$\sigma_i \geq TA * \sigma_R \quad (4.6)$$

Esto se traduce en:

$$\sigma_i \geq \sigma_y \quad (4.7)$$

Donde  $\sigma_i$  es el esfuerzo de von Misses del  $i$ -ésimo nodo,  $\sigma_R$  es el esfuerzo de referencia máximo de la estructura,  $\sigma_y$  es el esfuerzo de cedencia del material.  $TA$  es la Tasa de Adición de material y  $TR$  es la Tasa de Remoción de material. Estos dos últimos parámetros pueden ser llamados *parámetros de evolución*.

Ahora bien, la adaptación de cada individuo de una población al medio se realiza mediante la función de fitness. Para cuantificar esta adaptación primero debe decodificarse el cromosoma, ya que esta función está definida en el espacio fenotípico. El grado de adaptación de un individuo será el que determine su probabilidad de reproducción o incluso su eliminación de la población. Los GA trabajan en dos espacios diferentes de manera simultánea: el espacio de código y el de soluciones, o lo que es lo mismo en el espacio de genotipos y fenotipos. Los operadores genéticos trabajan en el espacio de genotipos mientras que la evaluación y selección tiene lugar en el espacio de fenotipos [6]. Los distintos operadores nos ayudan a definir



la manera en la que queremos que nuestra población “evolucione”. A continuación se describen sus parámetros.

El operador de selección que se utiliza en el presente trabajo es la *selección por torneo*, la cual es de las más efectivas y sencillas de implementar. Se seleccionan dos o más individuos de la población de modo que compitan entre sí para ser uno de los padres de la nueva generación. El vencedor será el individuo con mayor *fitness*, repitiendo este proceso hasta elegir todos los padres. Debido a sus características, es uno de los operadores de selección más eficientes y suele conducir a la obtención de óptimos absolutos, esta dada por la Ecuación 4.8.

$$\theta = 2^{n_{Tor1}} \quad (4.8)$$

El operador de cruce es también llamado operador de recombinación o *crossover* y es el responsable de realizar el apareamiento de dos individuos para generar dos o más hijos. En el presente trabajo se opta por utilizar el cruce binario simulado (*SBX* -  $\beta$ ), el cual simula el comportamiento de un operador de cruce binario para codificaciones reales. Este operador permite cierta exploración pero más centrada a zonas próximas a los padres y puede ser conveniente para acelerar la convergencia del algoritmo.

El factor  $\beta$  es llamado factor de propagación, que mide la propagación de los genes de los hijos respecto a los de sus padres y se calcula para el gen  $i$  como el cociente de las distancias entre los genes de los hijos y los genes de los padres.

Dado un conjunto de padres  $S_{p1} = p_1, \dots, p_n$  y  $S_{p2} = q_1, \dots, q_n$  y los hijos que deseamos obtener dado por  $S_{h1} = u_1, \dots, u_n$  y  $S_{h2} = v_1, \dots, v_n$ , el factor de propagación se calcula como:

$$\beta = \left| \frac{S_{p1} - S_{p2}}{S_{h1} - S_{h2}} \right| \quad (4.9)$$

Este factor clasifica los operadores de cruce en 3 tipos:

- Si  $\beta < 1$  el operador de cruce es contractivo, es decir los genes de los hijos se encuentran localizados entre los padres, por lo que el algoritmo se centrará en la explotación.
- Si  $\beta > 1$  el operador de cruce es expansivo, es decir los genes de los padres se encuentran localizados entre los genes de los hijos, lo cual se traduce en que estos explorarán zonas donde no alcanzaban sus padres por lo que el algoritmo se centrará en la exploración.
- Si  $\beta = 1$  el operador de cruce es estacionario, es decir los genes de los hijos son los mismos que los de los padres. Esto, por lo general no es deseable.

Dado que es posible obtener un comportamiento contractivo, estacionario o expansivo para este método, Deb [12] propone un ajuste polinómico a las ecuaciones para la correcta distribución de probabilidad, que deja las ecuaciones finales de los hijos como:

$$\begin{aligned} S_{h1} &= 0,5[(1 + \beta)S_{p1} + (1 - \beta)S_{p2}] \\ S_{h2} &= 0,5[(1 - \beta)S_{h1} + (1 + \beta)S_{h2}] \end{aligned} \quad (4.10)$$

Para este calculo, el valor de  $\beta$  se calcula de la siguiente manera:

$$\beta = \begin{cases} 2r^{\frac{1}{\eta+1}} & r \leq 0,5 \\ \left[ \frac{1}{2(1-r)} \right]^{\frac{1}{\eta+1}} & r > 0,5 \end{cases} \quad (4.11)$$

Donde  $r$  es un numero aleatorio desde cero hasta uno.

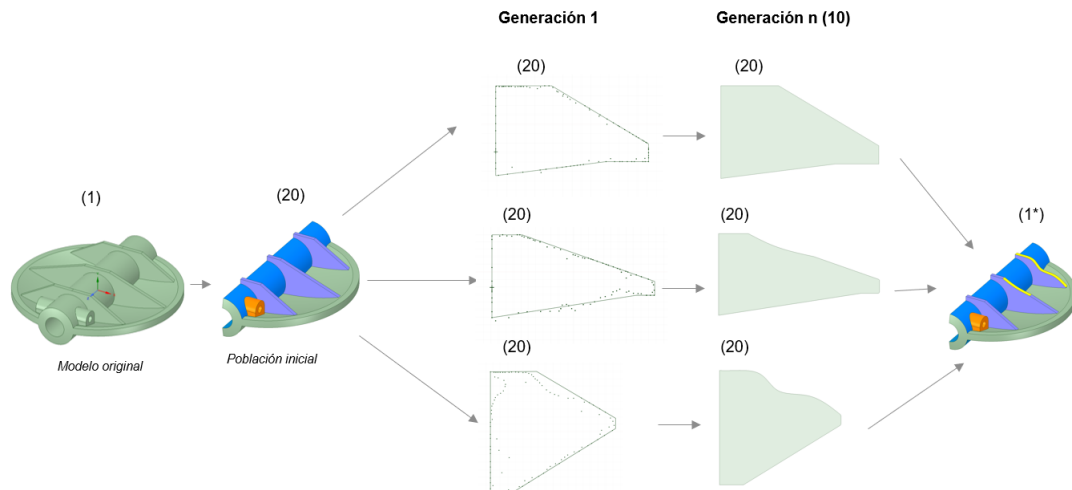
El operador de mutación es el responsable de realizar búsquedas más allá de los puntos generados por los genomas de los padres, básicamente de la exploración y diversidad de la generación. Al igual que las mutaciones naturales los hijos mutados usualmente tienen una aptitud muy inferior a los padres, por lo que el porcentaje de individuos mutados no puede ser muy elevado.

En este proyecto se usará el operador de mutación aleatoria uniforme. El cual nos dice que si el gen  $i$  resulta elegido para la mutación, se genera un número aleatorio dentro del dominio del gen, donde  $l_i$  y  $u_i$  representan los valores mínimos y máximos que puede tomar dicho gen.

Existen dos clases fundamentales de GA dependiendo de la estrategia de reemplazo empleada: con reemplazo generacional, también denominados Algoritmos Genéticos Simples (SGA por sus siglas en inglés) y los Algoritmos Genéticos Con Brecha Generacional (SSGA por sus siglas en inglés). En los primeros la población de padres es completamente reemplazada por la población de hijos una vez que estos han sido engendrados y mutados. Este trabajo esta creado como un GA simple.

El criterio de paro o detención del GA esta dado por un número máximo de generaciones o tiempo transcurrido. El algoritmo se detiene cuando ha alcanzado un numero de generaciones predeterminadas,  $N$ , o cuando ha transcurrido un determinado tiempo,  $T$ . Se utiliza la función de fitness para evitar que el algoritmo continúe realizando el bucle si no es detenido por ninguno de los criterios anteriores.

En la Figura 4.20 podemos ver a grandes rasgos como nuestra población inicial comienza con 20 individuos y como las siguientes generan también el conjunto de los 20 valores para cada una de las costillas. El diseño óptimo se escoge dentro de la población final.

**Figura 4.20:** Diagrama de Optimización de forma

## 4.11. Integación con Phyton

La librería de GA utilizada en el presente trabajo fue desarrollada por Mat Harvey [15] en 2017. Tiene licencia libre del Massachusetts Institute of Technology. Esta desarrollada en el código de programación Python. En el presente trabajo se utiliza Jupyter Lab como interfase de programación. De entre todas las características, se destacan las empleadas para los operadores de selección, cruce, mutación y reemplazo.

Estructura del Script:

1. Main.py – Archivo que contiene las características generales del código.
2. Network.py – Clase que representa la red a ser evolucionada. Se manda a llamar por medio de import los datos iniciales del primer componente.
3. Train.py – Archivo anexo de utilidad que permite a la clase Network.py llevar a cabo el training.
4. Optimizer.py – Clase que contiene el algoritmo genético para evolucionar la

red neuronal.

5. Brute.py – Archivo que realiza la iteración entre cada combinación de parámetros y que permite disminuir el tiempo de entrenamiento de la red.

## 5. Resultados

### 5.1. Valores de entrada

En base a toda la explicación dada en el capítulo anterior, se procede a iniciar el proceso del algoritmo. A esto se le conoce como una corrida. Dado el gasto computacional que genera simular múltiples diseños a la vez, debemos tener cuidado de tener todo definido correctamente y evitar errores de compilación a mitad del proceso.

Los valores de entrada de las variables de diseño fueron ya definidos en el capítulo 4, por lo tanto se omite su explicación de nueva cuenta en ésta sección. Con respecto al mallado estándar para el análisis de elementos finitos, tenemos los siguientes valores:

- Tamaño de malla: .08 in
- Presión: 1495 PSI

De igual manera, a todos los diseños dentro de las generaciones subsecuentes, se les aplicaran las mismas restricciones de frontera definidas en la subsección 4.3.3.

Con respecto al algoritmo genético, tenemos nuestra población inicial de 20 individuos, que se evolucionan a lo largo de 10 generaciones, para un total de 200 diseños evaluados dentro de la corrida.

Los valores de los parámetros de evolución los definimos de la siguiente manera tomando en cuenta la literatura disponible y casos de estudio de base utilizados [23]:

- TR=0.9

- TA=0.99
- RR=.001

En cuanto a los operadores genéticos, tenemos lo siguiente:

- Inicialización: se omite el operador dado que la población inicial se genera por medio de NN.
- Selección: selección por torneo.
- Cruce: cruce binario simulado ( $SBX - \beta$ ) para todos los cromosomas (nodos fijos, móviles, de conectividad y de material), con un valor de uno.
- Mutación: aleatoria uniforme. La tasa usualmente usada viene desde 0.005-0.01 y siguiendo el ejemplo del experimento descrito por Corbera [10], un valor de .01 es aplicado.
- Reemplazo: reemplazo generacional.
- Renacimiento: no se mencionó anteriormente, pero básicamente este operador indica que se reinicia completamente la población cuando la diversidad genotípica (de resultados) cae debajo de un valor de  $10^{-4}$ , siguiendo el ejemplo dado en el trabajo de Caballero [6], el cual solo se utiliza cuando llegamos a un resultado convergente prematuro, lo que representaría un estancamiento del algoritmo.
- Método de Paro: Dado por el número de generaciones pre-establecidas.

Así pues, estos valores fueron los utilizados para inicializar el algoritmo, los resultados se exponen en la siguientes secciones.

## 5.2. Cambio geométrico en las costillas

Durante cada generación, el número de puntos que constituyen las NURBS para las costillas varían dependiendo del cambio en los nodos que genere la nueva malla. Por lo cual, veremos una leve variación en la generación de puntos dependiendo de las modificaciones geométricas que se vayan realizando a las costillas mientras avanza el programa.

La mejor manera de mostrar las tendencias de los puntos generados fue con el valor promedio de cada una de las generaciones, esto es mostrado en la Tabla 5.1. Podemos observar como el programa comienza con un número fijo de 120 puntos por costilla y a través del paso de las generaciones este valor va cambiando hasta mantenerse estable dependiendo de los cambios de geometría que ocurrieran en la zona en cuestión.


	<b>Costilla 1</b>	<b>Costilla 2</b>	<b>Costilla 3</b>
<b>Generación 1</b>	120	120	120
<b>Generación 2</b>	136	118	141
<b>Generación 3</b>	110	100	112
<b>Generación 4</b>	122	109	102
<b>Generación 5</b>	127	119	100
<b>Generación 6</b>	122	122	119
<b>Generación 7</b>	101	98	99
<b>Generación 8</b>	97	106	117
<b>Generación 9</b>	103	102	122
<b>Generación 10</b>	95	94	136

**Cuadro 5.1:** Promedio de puntos generados por generación para cada costilla.


El ejemplo de la costilla 1 que se aprecia en la Figura 5.1 muestra la geometría de un individuo de la generación 10, en la cual tenemos un promedio de 95 puntos distribuidos dentro de la zona modificable.



**Figura 5.2:** Ejemplo de geometría de una costilla de Generación 10.



**Figura 5.1:** Puntos generados para la costilla 1



En la Figura 5.2, podemos ver el mismo ejemplo del individuo de la décima generación con el resultado de la geometría en 2D después de la creación de las NURBS a base de los puntos anteriores.

### 5.3. Elección del Individuo Final

Si bien sabemos que en base al algoritmo, al paso de las generaciones nos debemos acercar un resultado convergente, esto no significa precisamente que la generación final es la mejor. Dado que los GA están basados en la evolución natural de las especies, podemos inferir que los resultados tienen una tasa de variación ya que exploran la diversidad de resultados para mostrar cual tiene mejor adaptación a las restricciones impuestas.

	<b>Esfuerzo Equivalente (MPa)</b>	<b>Masa (Kg)</b>	<b>Volumen (m<sup>3</sup>)</b>
<b>Modelo inicial</b>	420.875	0.76021	9.25E-05

**Cuadro 5.2:** Valores de referencia del modelo inicial.

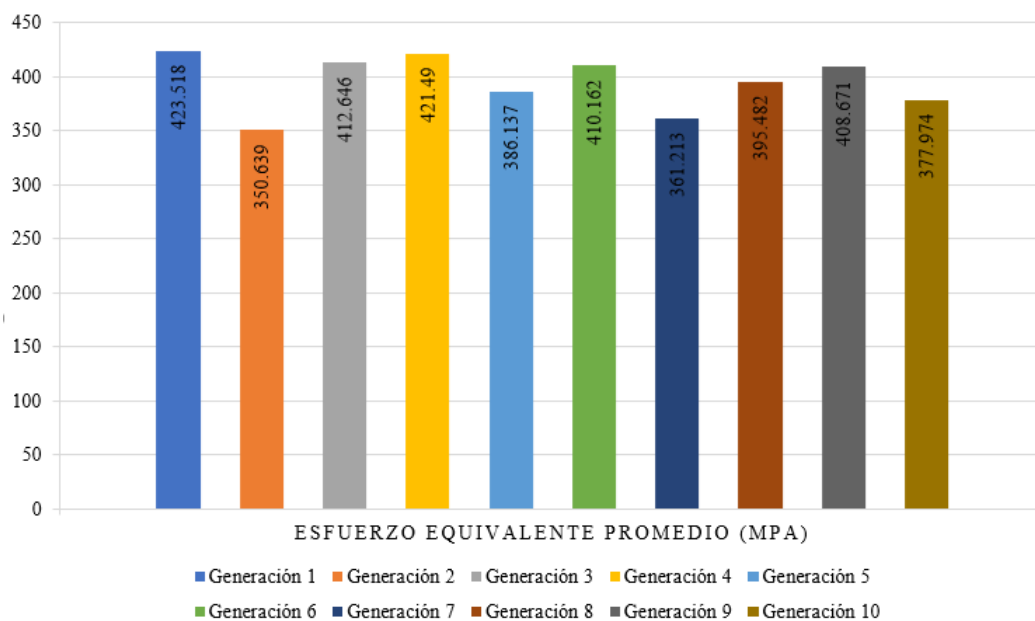
Debido a lo anterior, se analizaron los datos de todos los individuos en las 10 generaciones bajo el siguiente criterio: el diseño con el valor de esfuerzo equivalente y masa menor en comparación con los valores del modelo inicial fue el elegido como el óptimo. La Tabla 5.3 muestra los resultados:

	<b>Esfuerzo Equivalente (MPa)</b>	<b>Masa (Kg)</b>
<b>Poblacion inicial</b>	423.518	0.77296
<b>Generación 1</b>	418.174	0.75183
<b>Generación 2</b>	350.639	0.79448
<b>Generación 3</b>	412.646	0.74051
<b>Generación 4</b>	421.49	0.73842
<b>Generación 5</b>	386.137	0.75792
<b>Generación 6</b>	410.162	0.77882
<b>Generación 7</b>	361.213	0.75088
<b>Generación 8</b>	395.482	0.79374
<b>Generación 9</b>	408.671	0.78238
<b>Generación 10</b>	377.974	0.74923

**Cuadro 5.3:** Comparación del mejor individuo de cada generación.

Comparando los resultados con los valores de referencia mostrados en la Tabla 5.2 y en la Figura 5.3, podemos observar como precisamente, a lo largo del paso de las generaciones existe un decremento substancial en el esfuerzo equivalente promedio de los individuos. Es interesante destacar que una de las generaciones más tempranas (Generación 2) mostró el menor valor promedio del esfuerzo de Von Mises, sin embargo sobrepasó el valor en Kilogramos de la masa del diseño inicial.

**Figura 5.3:** Comparación de esfuerzo equivalente promedio del mejor individuo de cada generación




Se muestra también una variación negativa de aproximadamente 1% en relación al esfuerzo de referencia de la Tabla 5.2, pero esto fue solamente en la población inicial por lo cual sabemos que no fue un error del algoritmo dado que cae en el porcentaje de error esperado de las redes neuronales.

Por otro lado, la tendencia indica que aunque disminuimos por mucho el valor del esfuerzo equivalente promedio, tenemos en la mayoría de los casos un aumento de masa, llegando incluso hasta 0.79374 en la Generación 8. Aún así, podemos ver que

los valores de aumento no sobrepasan el 5 %, siendo el valor mas alto el encontrado en la misma generación 2 de la cual hablamos anteriormente. En la Figura 5.4 se muestra gráficamente la comparación en cuestión.


**Figura 5.4:** Comparación de masa del mejor individuo de cada generación.




Así pues, comparando los resultados de cada uno de los mejores individuos, se tomó la decisión de elegir el diseño de la generación 6 dado que fue el segundo mejor en relación a mejora en esfuerzo promedio y aún así presentó ahorro de peso. En la siguiente sección se hace una comparación de éste individuo contra la válvula inicial.

## 5.4. Comparación contra diseño inicial

En las Figuras 5.5 y 5.6 se ilustran los valores respectivos al esfuerzo equivalente promedio y deformación de la válvula simplificada que se usó como referencia

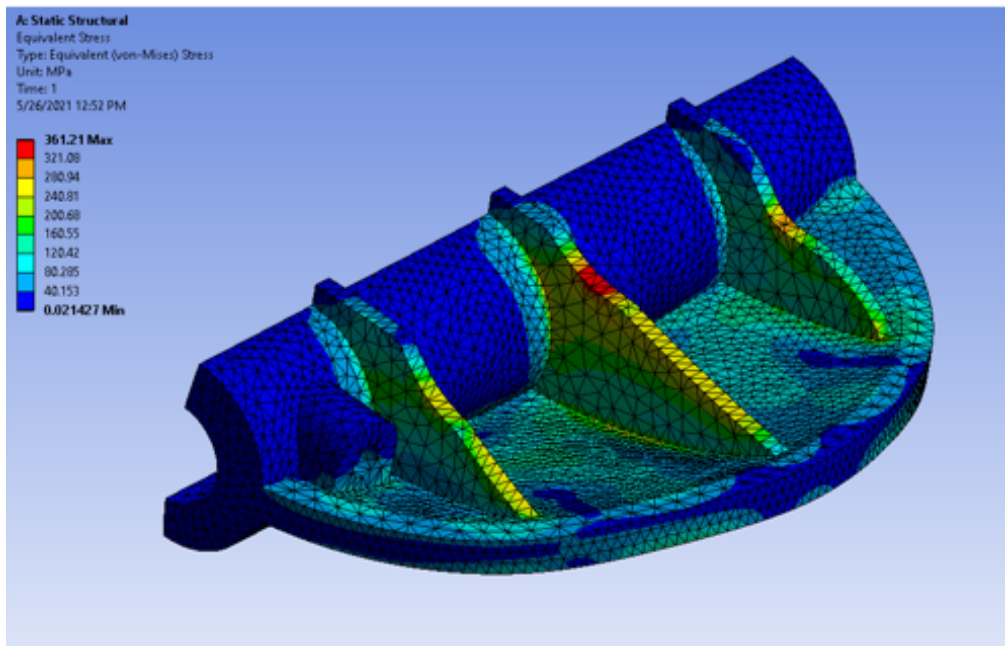
**Figura 5.5:** Modelo inicial: Esfuerzo.

Se observa como el valor del esfuerzo equivalente promedio para el modelo inicial se acerca a los 420 MPa y la deformación máxima de aproximadamente 0.1489 mm.


**Figura 5.6:** Modelo inicial: Deformación.

Ahora bien, si comparamos con el resultado del modelo final elegido de la última generación, como muestran la Figura 5.7 para el esfuerzo equivalente y la Figura 5.6 para la deformación, vemos una reducción considerable.

**Figura 5.7:** Resultado Final: Esfuerzo.




La distribución del esfuerzo en el diseño optimizado se muestra mas localizado en la zona de las costillas, como era de esperarse. El valor del esfuerzo equivalente muestra un decremento significativo de 420 MPa a 361 MPa, lo cual se traduce en una reducción del 14% con respecto al diseño de la válvula original.

**Figura 5.8:** Resultado final: Deformación.

Con respecto a la deformación, vemos por el contrario un aumento de aproximadamente el doble, para terminar con un máximo de 0.14876 mm. Esto se debe a que la distribución de esfuerzos presenta cambio principalmente al final de la zona de las costillas.

En la Figura 5.9 podemos observar con detalle como se ve el resultado final del disco de válvula de mariposa. Las zonas marcadas en un círculo rojo muestran las costillas que obtuvieron el mayor cambio durante el proceso.

**Figura 5.9:** Modelo Final

La tabla 5.4 nos permite ver a detalle la comparación tanto de esfuerzo equivalente, masa y volumen del modelo inicial y final. El resultado final nos arroja una mejora de 1.23 % aproximadamente en peso.

	Esfuerzo Equivalente (MPa)	Masa (Kg)	Volumen (m <sup>3</sup> )
Modelo inicial	420.87	0.76021	9.25E-05
Modelo final	361.21	0.75088	9.14E-05

**Cuadro 5.4:** Tabla de comparación de Resultados final.



## 6. Conclusiones y recomendaciones

### 6.1. Conclusiones generales

Este proyecto presentó una metodología de optimización multiobjetivo aplicada en una válvula de mariposa con el objetivo principal de reducir peso sin afectar la estabilidad estructural del componente. Todo esto con base en la integración de métodos heurísticos, análisis de elemento finitos, estudio de comportamiento geométrico y parámetros específicos de diseño.

El problema en cuestión fue simplificado definiendo geometrías básicas a las cuales se le hicieron subsecuentes análisis estructurales para obtener valores base. En una primera etapa, se realizó una optimización topológica al componente para detectar las áreas idóneas de modificación. Después se definieron variables de diseño, las cuales se re-trabajaron con ayuda de NURBS. Finalmente se utilizaron métodos heurísticos: primero NN para crear la población inicial de las válvulas y luego GA para crear generaciones de componentes con características mejoradas definidas por la función objetivo.

La metodología utilizada se basa en múltiples trabajos previos y se aplica con intención de servir en un futuro no solo para éste tipo de componente, si no para otros similares. Durante el presente trabajo fue necesario ajustar el alcance del mismo, terminando en una optimización enfocada a la zona de las costillas de la válvula. Lo anterior sirve como experiencia para tomar decisiones a futuro sobre la complejidad de nuestra función objetivo y como definir las variables diseño críticas para el componente en cuestión.

Así pues, en base a lo mostrado en la sección de resultados, las conclusiones más importantes se definen a continuación:

- Se optimizó la válvula contra el diseño inicial utilizando la metodología descrita en el presente trabajo.
- El análisis topológico inicial nos ayudó a definir las costillas como zonas de cambio del componente y los cambios significativos de ellas con respecto al patrón comprueba que el proceso de optimización fue efectivo.
- El algoritmo mostró sensibilidad al cambio de puntos para definir los NURBS que crean las costillas. Esto impactó directamente el tiempo de procesamiento del script.
- El algoritmo mostró estabilidad durante el proceso, ya que en la corrida final no mostró errores de compilación.
- Con esta metodología fue posible obtener un porcentaje mayor en reducción de material y costos de manufactura. Esto se traduce de manera concreta a una reducción de peso de aproximadamente 1.22 %
- Se disminuyeron los esfuerzos equivalentes en un 14 % con respecto al modelo de la válvula original. Los esfuerzos de la nueva válvula mostraron la tendencia de concentrarse cerca de la zona de las costillas donde ocurrió el cambio geométrico, a diferencia del modelo inicial que mostraba la zona del disco principal con más tensión.

Es importante mencionar que si bien, como ya se comprobó, la metodología funciona con éxito, no significa que pueda fungir como un reemplazo total del ingeniero de diseño dentro de las decisiones de creación o mejora de componentes. Se debe dejar en claro que ésta es una herramienta que ayuda proporcionando una solución óptima a un problema de diseño particular y que no se ve influenciada por factores externos, como la experiencia del diseñador en cuestión o las capacidades de manufactura, por ejemplo. Debe ser utilizada con el propio criterio de las necesidades

del mercado (costo, materiales, viabilidad de manufactura) y no como un resultado preponderantemente obligatorio.

## 6.2. Recomendaciones para trabajos futuros

Si bien éste proyecto fue concluido con éxito, se tiene claro que estuvo enfocado en un componente específico en condiciones muy generalizadas. Por lo cual, después de observar la gran gama de vertientes dentro del proceso y dadas las conclusiones anteriormente mencionadas, se hacen las siguientes sugerencias que se podrían implementar en trabajos futuros:

- Incluir análisis computacional de fluidos (CFD) para complementar los resultados, como se ha mostrado anteriormente en otros trabajos similares. Esto podría considerarse en futuras mejoras a la metodología actual.
- Crear metodologías específicas en otras familias de componentes para evaluar algún cambio de resultados.
- Expandir las opciones de variables de diseño, de ésta manera se pueden tomar mas consideraciones y asimismo presentar resultados mas precisos.
- Utilizar diferentes combinaciones de algoritmos genéticos, para así mejorar los tiempos de procesamiento.
- Unificar la metodología de diseño en una librería de optimización mas potente.
- Incluir diseño para manufactura aditiva (DFAM) dentro de la metodología, para aprovechar al máximo las capacidades de manufactura de ésta tecnología y asimismo restringir la geometría en función de ello.

## Referencias

- [1] Optimization Using Mathematica – from Wolfram Library Archive.
- [2] A. Ahrari, A. A. Atai, and K. Deb. Simultaneous topology, shape and size optimization of truss structures by fully stressed design based on evolution strategy. *Engineering Optimization*, 47(8):1063–1084, 8 2014.
- [3] A. J. Ajay, S. E. A. Stephen, and D. S. R. Smart. Shape optimization of submersible pump impeller design. In *2017 First International Conference on Recent Advances in Aerospace Engineering ({ICRAAE})*. IEEE, 3 2017.
- [4] R. U. Arechaga. Materiales de alto rendimiento para el sector más exigente - Metalmecánica, 2012.
- [5] A. Benaouali and S. Kachel. Structural wing sizing and planform shape optimization using multidisciplinary {CAD}-{CAE} integration process. In *2017 8th International Conference on Mechanical and Aerospace Engineering ({ICMAE})*. IEEE, 7 2017.
- [6] S. S. Caballero. *Optimización estructural y topológica de estructuras morfológicamente no definidas mediante algoritmos genéticos*. PhD thesis.
- [7] F. Cárdenas, Javier; Díaz Del Castillo. "SUPERALEACIONES . Technical report, 2015.
- [8] J. Cevallos Ampuero. APLICACIÓN DE REDES NEURONALES PARA OPTIMIZAR PROBLEMAS MULTIRESPUESTA EN MEJORA DE LA CALIDAD. *Industrial Data*, 7(2):031, 2014.
- [9] W. Chaiworapuek, J.-Y. Champagne, M. E. H. em, C. Kittichaikan, M. A.

- Wahid, S. Samion, N. A. C. Sidik, and J. M. Sheriff. An Investigation of the Water Flow Past the Butterfly Valve. AIP, 2010.
- [10] S. Corbera, J. L. Olazagoitia, J. A. Lozano, and R. Álvarez. OPTIMIZATION OF A BUTTERFLY VALVE DISC USING 3D TOPOLOGY AND. *Structural and Multidisciplinary Optimization*, 2017.
- [11] S. Corbera Caraballo, J. L. Olazagoitia Rodríguez, J. A. Lozano Ruiz, and R. Álvarez Fernández. Optimization of a butterfly valve disc using 3D topology and genetic algorithms. *Structural and Multidisciplinary Optimization*, 56(4):941–957, 10 2017.
- [12] K. Deb. Multi-objective Optimisation Using Evolutionary Algorithms: An Introduction. In *Multi-objective Evolutionary Optimisation for Product Design and Manufacturing*. 2011.
- [13] L. Dieter, George; Schmidt. *Engineering Design*. 2012.
- [14] L. dos Santos Coelho. Gaussian quantum-behaved particle swarm optimization approaches for constrained engineering design problems. *Expert Systems with Applications*, 37(2):1676–1683, 3 2010.
- [15] M. Harvey. GitHub - harvitronix/neural-network-genetic-algorithm: Evolving a neural network with a genetic algorithm., 2017.
- [16] L. R. Jenkinson, D. Rhodes, and P. Simpkin. *Civil Jet Aircraft Design*. AIAA education series. American Institute of Aeronautics and Astronautics, 1999.
- [17] S. Kang, D.-E. Kim, K.-K. Kim, and J.-O. Kim. Effect Analysis of Design Variables on the Disc in a Double-Eccentric Butterfly Valve. *The Scientific World Journal*, 2014:1–6, 2014.

- 
- [18] T. R. Kelley. Optimization, an Important Stage of Engineering Design. Technical report, 2010.
- [19] J. Kim, S. Yang, S. Baek, and S. Kang. Structural Design Strategy of Double-Eccentric Butterfly Valve using Topology Optimization Techniques. *World Academy of Science, Engineering and Technology*, 2012.
- [20] T. Larsson and M. Rönqvist. Simultaneous structural analysis and design based on augmented Lagrangian duality. *Structural Optimization*, 9(1):1–11, 2 1995.
- [21] S. Lemes, M. Cabaravdic, and N. Zaimovic-Uzunovic. Robotic manipulation in dimensional measurement. In *2013 {XXIV} International Conference on Information, Communication and Automation Technologies ({ICAT})*. IEEE, 10 2013.
- [22] J. R. P. López. *Contribución a los métodos de optimización basados en procesos naturales y su aplicación a la medida de antenas en campo próximo*. PhD thesis, 2005.
- [23] D. Lozano Trejo. *Optimización estructural : diseño mecánico óptimo de piezas para inyección de plástico*. PhD thesis, 2012.
- [24] A. Majdi and M. Beiki. Evolving neural network using a genetic algorithm for predicting the deformation modulus of rock masses. *International Journal of Rock Mechanics and Mining Sciences*, 47(2):246–253, 2 2010.
- [25] A. Mateos Andaluz. Algoritmos Evolutivos y Algoritmos Genéticos. Technical report.
- [26] B. Melián, J. A. M. Perez, and J. M. Moreno-Vega. Metaheuristics: A global view. *{INTELIGENCIA} {ARTIFICIAL}*, 7(19), 7 2003.

- 
- [27] E. S. Menon. *Transmission Pipeline Calculations and Simulations Manual*. Elsevier Inc., 1 2015.
- [28] A. M. Mirzendehtel and K. Suresh. Support Structure Constrained Topology Optimization for Additive Manufacturing. Technical report.
- [29] A. Mortazavi and V. To\ugan. Simultaneous size, shape, and topology optimization of truss structures using integrated particle swarm optimizer. *Structural and Multidisciplinary Optimization*, 54(4):715–736, 4 2016.
- [30] T. E. Müller and E. van der Klashorst. A Quantitative Comparison Between Size, Shape, Topology and Simultaneous Optimization for Truss Structures. *Latin American Journal of Solids and Structures*, 14(12):2221–2242, 12 2017.
- [31] D. J. Munk, T. Kipouros, G. A. Vio, G. T. Parks, and G. P. Steven. Multiobjective and multi-physics topology optimization using an updated smart normal constraint bi-directional evolutionary structural optimization method. *Structural and Multidisciplinary Optimization*, 2018.
- [32] D. J. Munk, G. A. Vio, and G. P. Steven. Topology and shape optimization methods using evolutionary algorithms: a review. *Structural and Multidisciplinary Optimization*, 52(3):613–631, 9 2015.
- [33] P. P. Nagpurkar, A. Sangamner Ahemadnagar, and I. R. S Tajane. Design and Development of Double Offset Butterfly Valve. Technical Report 7, 7 2014.
- [34] P. Nakamoto. *Neural Networks and Deep Learning: Neural Networks and Deep Learning, Deep Learning Explained to Your Granny*. Machine Learning. CreateSpace Independent Publishing Platform, 2018.
- [35] A. Nickabadi, M. M. Ebadzadeh, and R. Safabakhsh. A novel particle swarm



- optimization algorithm with adaptive inertia weight. *Applied Soft Computing*, 11(4):3658–3670, 6 2011.
- [36] S. Niemann, B. Kolesnikov, H. Lohse-Busch, C. Hühne, O. M. Querin, V. V. Toropov, and D. Liu. The use of topology optimisation in the conceptual design of next generation lattice composite aircraft fuselage structures. *Aeronautical Journal*, 2013.
- [37] K. Ogawa and T. Kimura. Hydrodynamic characteristics of a butterfly valve {\\textemdash} Prediction of torque characteristics. *{ISA} Transactions*, 34(4):327–333, 12 1995.
- [38] O. M. Querin. {ESO} Computer Program Evolve97. In *Evolutionary Structural Optimization*, pages 148–182. Springer London, 1997.
- [39] C. Renzi. A genetic algorithm-based integrated design environment for the preliminary design and optimization of aeronautical piston engine components. *International Journal of Advanced Manufacturing Technology*, 86(9-12):3365–3381, 10 2016.
- [40] C. Riba Romeva. Selección de materiales en el diseño de máquinas. In *Selección de materiales en el diseño de máquinas*, page 25. EDICIONS UPC, politext edition, 2008.
- [41] M.-S. Shin, J.-Y. Yoon, I.-W. Park, S.-H. Lee, H.-Y. Park, and S.-H. Jung. A Study on Structural Analysis of Butterfly Valve Components by Pressure Testing of the Industrial Standard. *Journal of Fluid Machinery*, 14(3):5–9, 6 2011.
- [42] O. Sigmund. A 99 line topology optimization code written in matlab. *Structural and Multidisciplinary Optimization*, 21(2):120–127, 4 2001.

- 
- [43] O. Sigmund and P. M. Clausen. Topology optimization using a mixed formulation: An alternative way to solve pressure load problems. *Computer Methods in Applied Mechanics and Engineering*, 196(13-16):1874–1889, 3 2007.
- [44] X. G. Song, L. Wang, S. H. Baek, and Y. C. Park. Multidisciplinary optimization of a butterfly valve. *{ISA} Transactions*, 48(3):370–377, 7 2009.
- [45] G. N. Vanderplaats and F. Moses. Automated design of structures for optimum geometry. *ASCE J Struct Div*, page 98(ST3):671–690, 1972.
- [46] S. Velazquez, F.; Santillan. Diseño óptimo evolutivo. *Revista Ingeniería, Investigación y Tecnología, VII*, pages 139–150, 2006.
- [47] J. H. Zhu, X. J. Gu, W. H. Zhang, and P. Beckers. Structural design of aircraft skin stretch-forming die using topology optimization. *Journal of Computational and Applied Mathematics*, 2013.
- [48] J.-H. Zhu, W.-H. Zhang, and L. Xia. Topology Optimization in Aircraft and Aerospace Structures Design. *Archives of Computational Methods in Engineering*, 23(4):595–622, 4 2015.