



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA MECÁNICA

DISEÑO GENERATIVO DE METAMATERIALES MECÁNICOS BLANDOS

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL MECÁNICO

JAVIER EDUARDO VARGAS PARRA

PROFESOR GUÍA:
JUAN CRISTÓBAL SEBASTIÁN ZAGAL MONTEALEGRE

MIEMBROS DE LA COMISIÓN:
BRUNO GROSSI CÓRDOVA
ÁLVARO ZÁRATE ACEVEDO

SANTIAGO DE CHILE
2021

RESUMEN DE LA MEMORIA PARA OPTAR
AL TÍTULO DE INGENIERO CIVIL MECÁNICO
DE LA INGENIERÍA
POR: **JAVIER EDUARDO VARGAS PARRA**
FECHA: 2021
PROF. GUÍA: JUAN CRISTÓBAL SEBASTIÁN ZAGAL MONTEALEGRE

DISEÑO GENERATIVO DE METAMATERIALES MECÁNICOS BLANDOS

Los metamateriales mecánicos se caracterizan, entre otras cosas, por poseer coeficiente de Poisson negativo. Esta propiedad se denomina auxeticidad y es de gran interés en distintas aplicaciones, como la absorción de impacto y vibraciones, entre otros. Los metamateriales adquieren esta característica mediante su estructura, la cual puede ser modificada según el comportamiento auxético que se quiera alcanzar. Los metamateriales comúnmente están compuestos por celdas o unidades básicas, las cuales determinan mediante su estructura las propiedades del material.

El coeficiente de Poisson representa un parámetro que mide el ensanchamiento o estrechamiento transversal de un material al ser estirado longitudinalmente. Un coeficiente de Poisson positivo indica que un material se ensancha al ser comprimido y se estrecha al ser estirado. La gran mayoría de los materiales poseen un coeficiente de Poisson positivo.

El presente trabajo tiene como objetivo principal el desarrollar un método evolutivo fácilmente repetible que permita variar la estructura de un metamaterial según el grado de auxeticidad que se quiera lograr. Para lograr esta meta, se plantean objetivos específicos, como lo son el desarrollar un genoma para representar la estructura de un metamaterial, desarrollar un método para evaluar el desempeño de las estructuras y establecer un entorno evolutivo que permita generar soluciones óptimas.

Los resultados obtenidos indican que el método es capaz de generar estructuras con comportamiento auxético para distintos casos, ya sea en compresión o en tracción. Incluso se puede generar un conjunto de soluciones que busquen optimizar dos objetivos de forma simultánea, como puede ser buscar coeficientes de Poisson específicos para distintos casos.

En contrapartida, muchas veces las estructuras generadas poseen una estructura muy similar, que solo varía levemente entre caso y caso. Este comportamiento puede deberse al genoma desarrollado, el cual puede no proveer un abanico suficiente de posibles soluciones a las que el algoritmo pueda converger.

Finalmente, se concluye que el método puede ser una muy buena herramienta para generar estructuras cuadradas y auxéticas en 2D que requieran simetría en su estructura. Este método posee gran eficacia tanto para maximizar el comportamiento auxético, como para resolver problemas que busquen uno o varios comportamientos específicos a la vez.

Agradecimientos

Quiero agradecer por esta memoria a mi familia, sin la cual jamás habría llegado al lugar donde me encuentro hoy en día, tanto como persona, como estudiante y como futuro profesional. Gracias por todos los años de amor, respeto, apoyo y cariño.

Tabla de Contenido

1. Introducción	1
1.1. Objetivos	2
1.1.1. Objetivo General	2
1.1.2. Objetivos Específicos	2
1.2. Alcances	2
2. Antecedentes	3
2.1. Metamateriales mecánicos blandos	3
2.2. Estructuras auxéticas	4
2.3. Simulaciones de deformación	10
2.4. Diseño Generativo	11
2.5. Algoritmos genéticos	13
3. Metodología	15
3.1. Creación del genotipo	15
3.2. Evaluación del fenotipo	19
3.3. Fitness y función objetivo	21
3.4. Proceso evolutivo	22
3.5. Casos de estudio	23
3.5.1. Tracción	23
3.5.2. Compresión	23
3.5.3. Doble objetivo	24
4. Resultados	25
4.1. Casos de tracción	25
4.1.1. Estructuras generadas	26
4.1.1.1. Curvas de aprendizaje	32
4.2. Casos de compresión	37
4.2.1. Estructuras generadas	39
4.2.2. Curvas de aprendizaje	43
4.3. Doble objetivo	47
4.3.1. Estructuras generadas	47
4.3.2. Curvas de aprendizaje	47
5. Análisis y discusión	49
5.1. Tracción	49
5.1.1. Estructuras generadas	50
5.1.2. Curvas de aprendizaje	51

5.2. Compresión	51
5.2.1. Estructuras generadas	52
5.2.2. Curvas de aprendizaje	53
5.3. Doble objetivo	53
5.3.1. Estructuras generadas	54
5.3.2. Curvas de Aprendizaje	54
6. Conclusión	55
Bibliografía	58

Índice de Tablas

3.1.	Parámetros utilizados en el GA.	22
3.2.	Casos de estudio en tracción.	23
3.3.	Casos de estudio en Compresión.	23
3.4.	Parámetros de entrada y objetivos buscados	24
4.1.	Resumen de resultados, primera parte. Búsqueda de máxima auxeticidad. . . .	25
4.2.	Resumen de resultados, segunda parte. Búsqueda de Poisson Ratio específicos. . . .	25
4.3.	Resumen de resultados, primera parte. Búsqueda de máxima auxeticidad. . . .	37
4.4.	Resumen de resultados, segunda parte. Búsqueda de Poisson Ratio específico. . . .	37
4.5.	Resumen de resultados para tres estructuras generadas por el algoritmo. . . .	47

Índice de Ilustraciones

2.1.	Celda unitaria y metamaterial [4]	3
2.2.	Metamaterial mecánico blando adquiriendo una forma predeterminada [9]	4
2.3.	Parámetros para calcular Poission Ratio en 2D [7]	4
2.4.	Ejemplo de celda unitaria auxética en 2D y en 3D [12]	5
2.5.	Coeficiente de Poisson vs deformación, celda unitaria en 2D [12]	6
2.6.	Tabla con estructuras reentrantes [6]	7
2.7.	Tabla con estructuras de polígonos rotatorios [6]	8
2.8.	Ejemplo de estructura quirál [6]	9
2.9.	tabla con estructuras porosas [6]	9
2.10.	Análisis de elementos finitos simulando de forma eficiente la deformación de tres matrices distintas en 2D (a con d, b con e y c con f) [12]	10
2.11.	Análisis de elementos finitos simulando de forma eficiente la deformación en una matriz 3D [12]	11
2.12.	Parametrización CAD para el de diseño (a) parlantes y (b) motocicletas [11] .	12
2.13.	Soluciones de diseño generados mediante diseño generativo para (a) parlantes y (b) motocicletas [6]	12
2.14.	Ejemplo de curva de aprendizaje, evolución del fitness hasta alcanzar convergencia [8]	14
3.1.	Matrices con distintos números de celdas. (a) Matriz de 4x4 celdas. (b) Matriz de 2x2 celdas	16
3.2.	Estructura de una celda. (a) Celda completa. (b) Cuadrante de diseño	16
3.3.	Parametrización de puntos externos. (a) Segmentos que determinan el cuadrante de diseño. (b) Puntos externos (verde) con parámetros de posición = 0.5. (c) Punto externo (verde) con parámetro de posición = 0.1	17
3.4.	Parametrización de puntos internos. (a) Segmentos hacia el centro del cuadrante. (b) Puntos internos (verde) con parámetros de posición = 0.5. (c) Puntos internos (verde) con parámetros de posición = 0.1	17
3.5.	Generación de la estructura de la celda. (a) Unión (verde) de puntos internos. (b) Continuidad con el resto de la celda (verde). (c) Continuidad con otras celdas. (d) Estructura del cuadrante final.	18
3.6.	Estructura final del metamaterial. (a) Celda unitaria completa. (b) Matriz de 3x3, con estructuras horizontales en la parte superior e inferior.	19
3.7.	Matriz sometida a deformación. Fuerza de deformación (flechas rojas) y apoyos simples (verde).	20
3.8.	Puntos utilizados para medir longitud transversal. (a) Largo inicial (pre-compresión).(b) Largo final (post-compresión).	21
4.1.	Dimensiones de las estructuras generadas para distintos porcentajes de tracción, caso de máxima auxeticidad.	26

4.2.	Fenotipos obtenidos para caso N°1. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.6. (d) Estructura con Poisson Ratio = -0.6 en tracción.	27
4.3.	Fenotipos obtenidos para caso N°2. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.5. (d) Estructura con Poisson Ratio = -0.5 en tracción.	28
4.4.	Fenotipos obtenidos para caso N°3. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.6. (d) Estructura con Poisson Ratio = -0.6 en tracción.	29
4.5.	Fenotipos obtenidos para caso N°4. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.3. (d) Estructura con Poisson Ratio = -0.3 en tracción.	30
4.6.	Fenotipos obtenidos para caso N°5. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.4. (d) Estructura con Poisson Ratio = -0.4 en tracción.	31
4.7.	Curva de aprendizaje caso N°1, máxima auxeticidad	32
4.8.	Curva de aprendizaje caso N°2, máxima auxeticidad	32
4.9.	Curva de aprendizaje caso N°3, máxima auxeticidad	33
4.10.	Curva de aprendizaje caso N°4, máxima auxeticidad	33
4.11.	Curva de aprendizaje caso N°5, máxima auxeticidad	34
4.12.	Max. Fitness versus generaciones caso N°1, Poisson Ratio = -0.6	34
4.13.	Max. Fitness versus generaciones caso N°2, Poisson Ratio = -0.5	35
4.14.	Max. Fitness versus generaciones caso N°3, Poisson Ratio = -0.6	35
4.15.	Max. Fitness versus generaciones caso N°4, Poisson Ratio = -0.3	36
4.16.	Max. Fitness versus generaciones caso N°5, Poisson Ratio = -0.4	36
4.17.	Dimensiones de las estructuras generadas para distintos porcentajes de compresión, caso de máxima auxeticidad.	38
4.18.	Fenotipos obtenidos para caso N°6. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -1.9. (d) Estructura con Poisson Ratio = -1.9 en tracción.	39
4.19.	Fenotipos obtenidos para caso N°7. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -1.2. (d) Estructura con Poisson Ratio = -1.2 en tracción.	40
4.20.	Fenotipos obtenidos para caso N°8. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.6. (d) Estructura con Poisson Ratio = -0.6 en tracción.	41
4.21.	Fenotipos obtenidos para caso N°9. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.35. (d) Estructura con Poisson Ratio = -0.35 en tracción.	42
4.22.	Curva de aprendizaje caso N°6, máxima auxeticidad	43
4.23.	Curva de aprendizaje caso N°7	43
4.24.	Curva de aprendizaje caso N°8	44
4.25.	Curva de aprendizaje caso N°9	44
4.26.	Max. Fitness versus generaciones, caso N°6, Poisson Ratio = -1.9	45
4.27.	Max. Fitness versus generaciones, caso N°7, Poisson Ratio = -1.2	45
4.28.	Max. Fitness versus generaciones, caso N°8, Poisson Ratio = -0.6	46
4.29.	Max. Fitness versus generaciones, caso N°9, Poisson Ratio = -0.35	46

4.30.	Fenotipos obtenidos para caso doble objetivo. (a) Estructura óptima para fitness N°1. (b) Estructura óptima para fitness N°2. (c) Estructura que más se acerca a ambos óptimos.	47
4.31.	Curvas de Fitness por generación, caso doble objetivo	48

Capítulo 1

Introducción

Los metamateriales en general son cada vez más usados en distintos ámbitos de la ingeniería. A diferencia de la mayoría de los materiales, los metamateriales no deben sus propiedades a su composición química o al tratamiento térmico al que fueron sometidos, sino que a su estructura. Estas estructuras le permiten a los metamateriales alcanzar propiedades difícilmente obtenibles en otros materiales, lo cual hace que su estudio y diseño sea de gran interés en la búsqueda de nuevos materiales.

Los metamateriales mecánicos son estructuras que permiten alcanzar propiedades mecánicas particulares muy difíciles de obtener mediante otros medios. Se caracterizan, en general, por estar constituidos por un arreglo o matriz de unidades más pequeñas, denominadas celdas. Estos arreglos le brindan al material propiedades mecánicas mejoradas como pueden ser altas fuerzas específicas, capacidad de absorción de impacto, coeficientes de Poisson negativos, entre muchas otras.

El poseer un coeficiente de Poisson negativo se denomina auxeticidad y es una propiedad muy utilizada en los metamateriales mecánicos blandos. Este trabajo propone desarrollar un método para el cual optimizar el comportamiento auxético de un metamaterial, generando nuevas estructuras para celdas unitarias. Para ello, se utiliza el diseño generativo, un proceso de diseño iterativo que utiliza algoritmos evolutivos para generar nuevas soluciones.

El diseño generativo ha adquirido gran protagonismo en los últimos años debido al desarrollo de nuevos softwares y herramientas que hacen más simple su implementación. Este proceso aprovecha la capacidad que poseen las computadoras de procesar grandes cantidades de información para explorar múltiples combinaciones de parámetros previamente determinados para resolver un problema. Este proceso itera sobre sí mismo hasta alcanzar soluciones óptimas, muchas veces inalcanzables por la mente humana mediante un proceso analítico.

1.1. Objetivos

1.1.1. Objetivo General

Desarrollar un método evolutivo fácilmente repetible que permita generar estructuras de metamateriales según el grado de auxeticidad que se quiera lograr.

1.1.2. Objetivos Específicos

- Desarrollar una representación genética de un metamaterial y su estructura mediante un cromosoma.
- Establecer un entorno de evolución que permita evaluar el comportamiento auxético de una estructura en forma rápida y eficiente.
- Realizar el proceso evolutivo para optimizar el comportamiento mecánico del metamaterial.
- Estudiar la efectividad del método evolutivo para distintos casos.

1.2. Alcances

- Se trabaja solamente con estructuras en 2D. No se explorarán estructuras en 3D.
- El método se limita a generar metamateriales conformados por un único tipo celda unitaria, el que se repite de forma periódica para conformar la estructura.
- Se generan celdas unitarias cuadradas, las cuales estarán ordenadas, a su vez, en matrices cuadradas.
- La dimensión de las matrices generadas es de 10x10 centímetros y de 3x3 celdas unitarias.
- Solo se optimiza el comportamiento auxético del metamaterial y su coeficiente de Poisson, dejando de lado el estudio de otras propiedades mecánicas.
- Las estructuras son sometidas a estudios de tracción y compresión.

Capítulo 2

Antecedentes

2.1. Metamateriales mecánicos blandos

Los **metamateriales** se pueden definir como estructuras artificiales compuestas por unidades básicas más pequeñas, diseñadas con el propósito de brindarle al material un conjunto de propiedades determinadas. Se caracterizan por el potencial de adquirir propiedades difícilmente obtenibles en materiales convencionales. A las unidades básicas que constituyen un material se les denomina comúnmente como células o **celdas**. Dado que las propiedades del metamaterial son dependientes de su estructura, el diseño de nuevos metamateriales se reduce al diseño y ordenamiento de las celdas que lo constituyen. [13] La Figura 2.1 muestra un ejemplo de cómo, a partir de una celda unitaria, se puede construir un metamaterial.




Figura 2.1: Celda unitaria y metamaterial [4]

Los metamateriales pueden adquirir propiedades electromagnéticas, mecánicas, acústicas, ópticas o de otros tipos. En particular, los metamateriales mecánicos son aquellos que buscan potenciar propiedades mecánicas, tales como absorción de impactos, altas fuerzas específicas, **coeficientes de Poisson negativos** (auxeticidad), amortiguamiento de vibraciones, por mencionar algunas. [4]

Los metamateriales mecánicos blandos, en particular, se caracterizan por poseer baja rigidez y alta flexibilidad. Este tipo de material es altamente utilizado en la robótica blanda y son comúnmente construidos con polímeros elastómeros como la silicona caucho. Uno de sus principales ramas de estudio es la búsqueda de comportamientos auxéticos, con el objetivo de alcanzar deformaciones predeterminadas al verse sometidos a fuerzas de tracción, compresión o torsión. [9]



Figura 2.2: Metamaterial mecánico blando adquiriendo una forma predeterminada [9]

2.2. Estructuras auxéticas

El **Poisson Ratio** (coeficiente de Poisson en inglés) se define formalmente como el cociente entre la deformación transversal o lateral y la deformación longitudinal de un material.

Definición 2.1 (ver [7]) *Poisson Ratio - fórmula general*

$$\nu = -\frac{d\epsilon_{trans}}{d\epsilon_{axial}}$$

Donde ϵ_{trans} es la deformación transversal y ϵ_{axial} es la deformación longitudinal. Para superficies en 2D, la definición se simplifica.

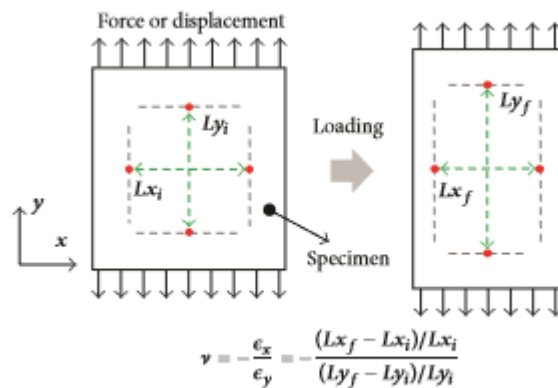


Figura 2.3: Parámetros para calcular Poisson Ratio en 2D [7]

Definición 2.2 (ver [7]) *Poisson Ratio - Caso 2D*

$$\nu = -\frac{[Lx_f - Lx_i] \setminus Lx_i}{[Ly_f - Ly_i] \setminus Ly_i}$$

Un Poisson ratio positivo describe un material que se ensancha al ser comprimido y se estrecha al ser estirado. La gran mayoría de los materiales poseen un coeficiente positivo. Su valor tiende a fluctuar entre 0.2 y 0.5. En los aceros, el valor estándar es de 0.3. Por el contrario, un Poisson Ratio negativo describe el comportamiento inverso, es decir, un material que es estrecha al ser sometido a tracción y que se comprime al ser sometido a compresión. Esta propiedad se denomina auxeticidad. [2]

Los metamateriales se caracterizan por alcanzar distintos grados de auxeticidad mediante distintas estructuras. Un ejemplo básico se muestra en la Figura 2.4, en donde se muestra una celda unitaria en 2D que puede poseer o no un Poisson Ratio negativo de acuerdo con el ángulo que presente en la estructura que se muestra. También se ha replicado esa misma estructura para celdas 3D. [12]

Para dichas celdas, los valores del Poisson Ratio según el ángulo elegido versus la deformación longitudinal aplicada a la celda 2D se pueden observar en la 2.5. Se puede apreciar cómo, para esta estructura, el coeficiente de Poisson en ningún caso es constante en relación con el grado de deformación que sufre. Esto indica que dos celdas que posean un mismo Poisson Ratio al inicio de una deformación podrían no poseer el mismo comportamiento una vez que dicha deformación progresa. [12]




Figura 2.4: Ejemplo de celda unitaria auxética en 2D y en 3D [12]

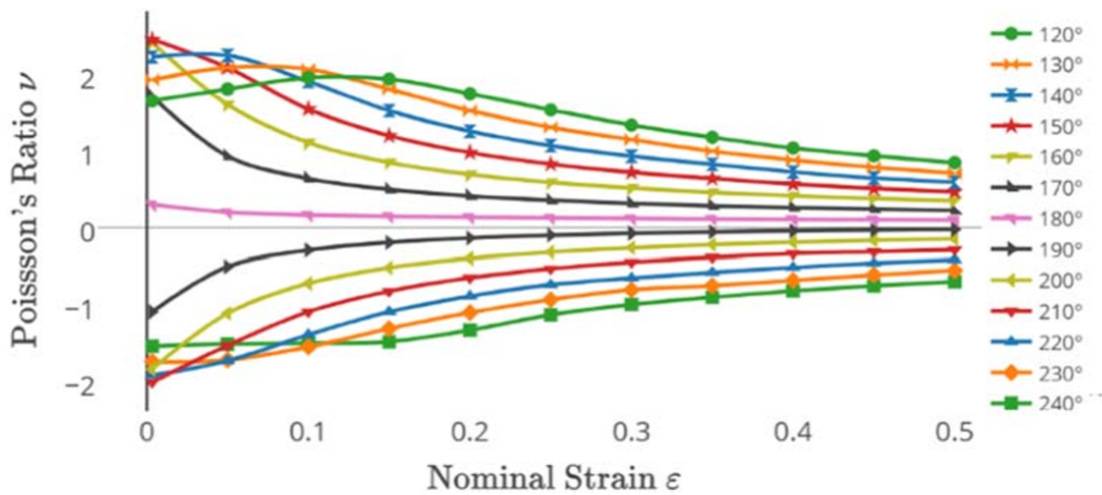


Figura 2.5: Coeficiente de Poisson vs deformación, celda unitaria en 2D [12]

Según su mecanismo de deformación, las estructuras celulares de un metamateriales pueden ser clasificadas en distintos tipos: [6]

- Estructuras reentrantes: Son estructuras de tipo panal o enrejado. Obtienen un comportamiento auxético debido a que los elementos que están siendo sometidos a compresión empujan otros elementos hacia el centro, angostando el material. En caso de sufrir tracción, arrastran otros elementos lejos del centro, ensanchando el material.
- Estructuras quirales: Estas estructuras consisten en ligamentos adheridos tangencialmente a anillos rígidos. El comportamiento auxético proviene de la rotación de dichos anillos, causando que los ligamentos se doblen y enrollen alrededor de ellos.
- Polígonos rotatorios: El comportamiento auxético del metamaterial se obtiene mediante la rotación de polígonos rígidos unidos entre sí mediante bisagras. Los polígonos al juntarse ocupan los espacios vacíos dentro del material, reduciendo su volumen.
- Estructuras porosas: Estructuras sólidas con poros en su interior. Su comportamiento auxético se debe a la tendencia del material de converger hacia sus poros al verse comprimido.



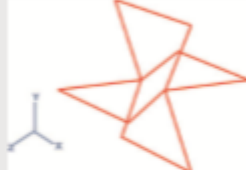
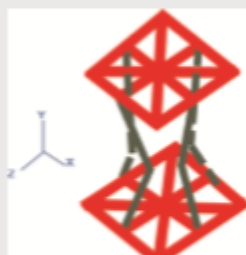
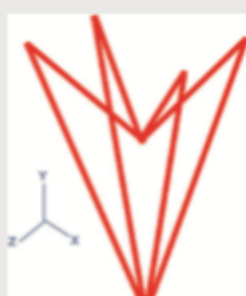

Classification	Type of auxetic structure	Geometry
Re-entrant type	2D Re-entrant Evans ^[16,21]	
	2D Re-entrant triangular ^[17,18]	
	3D Re-entrant variant 1 ^[164]	
	3D Re-entrant variant 2 ^[14]	
	3D Re-entrant triangular ^[19]	
	Re-entrant stars variant 1 (Rotational symmetry of order 3) ^[20]	

Figura 2.6: Tabla con estructuras reentrantes [6]

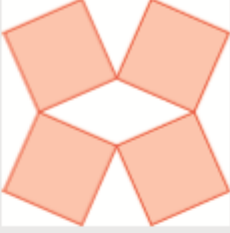
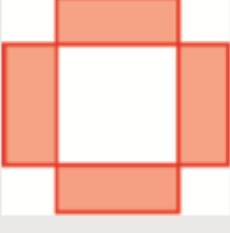



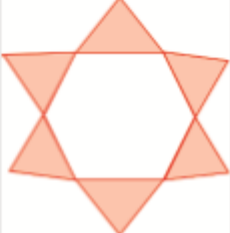
Classification	Type of auxetic structure	Geometry
Rotating polygons	Rotating squares ^[26]	
	Rotating rectangles variant 1 (Empty loops are squares) ^[27]	
	Rotating rectangles variant 2 (Empty loops are rectangles) ^[27]	
	Rotating rhombi (can be both Type I and Type II) ^[28]	
	Rotating parallelograms (can be both Type I and Type II) ^[28]	
	Rotating triangles ^[29]	

Figura 2.7: Tabla con estructuras de polígonos rotatorios [6]


Classification	Type of auxetic structure	Geometry
Chiral type	Chiral circular ^[22]	

Figura 2.8: Ejemplo de estructura quiral [6]

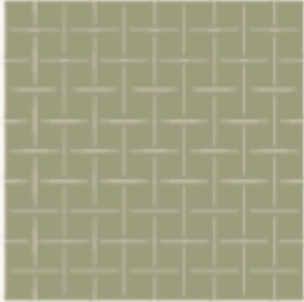


Classification	Type of auxetic structure	Geometry
Perforated sheets	Perpendicular oriented cuts ^[36]	
	Random oriented cuts ^[37]	
	Diamond perforations ^[31]	

Figura 2.9: tabla con estructuras porosas [6]

2.3. Simulaciones de deformación

Simular el comportamiento auxético de una estructura al verse sometida a esfuerzo y/o deformación constituye un aspecto vital a la hora de diseñar metamateriales mecánicos. En este ámbito, el **análisis de elementos finitos (FEA, por sus siglas en inglés)** ha demostrado poseer gran eficacia y precisión, tanto para el análisis de celdas unitarias como para matrices más complejas con múltiples celdas unitarias. La Figura 2.10 muestra la deformación de un metamaterial obtenida mediante simulación con análisis de elementos finitos versus el comportamiento real de dicho metamaterial una vez fabricado. [12]

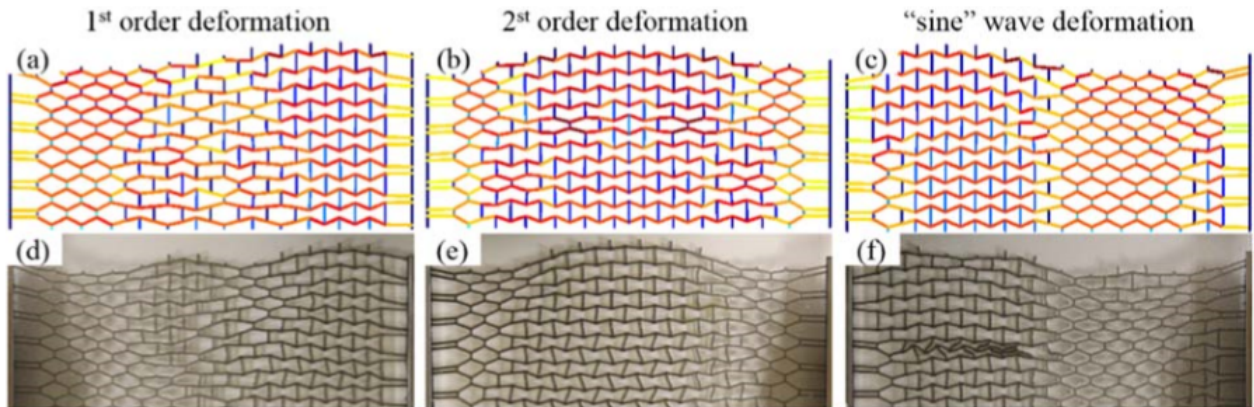


Figura 2.10: Análisis de elementos finitos simulando de forma eficiente la deformación de tres matrices distintas en 2D (a con d, b con e y c con f) [12]

Si bien los FEA resultan muy confiables a la hora de obtener precisión en las simulaciones realizadas, poseen el inconveniente de, muchas veces, ser procesos que requiere mucho tiempo y poder de procesamiento de datos. Un análisis muy a fondo puede tomar mucho tiempo, mientras que un análisis superficial puede no ser lo suficientemente preciso. Estos aspectos deben ser considerados a la hora de realizar un FEA.




Figura 2.11: Análisis de elementos finitos simulando de forma eficiente la deformación en una matriz 3D [12]

2.4. Diseño Generativo

El **diseño generativo** es una herramienta de diseño cada vez más utilizada en el mundo de la ingeniería. Se define como un proceso iterativo moderno de diseño digital, el cual aprovecha la capacidad de procesamiento de datos de las herramientas computacionales para generar soluciones a problemas de diseño [1]. Mediante la utilización de algoritmos, se busca generar y evaluar la mayor cantidad de soluciones posibles hasta encontrar un resultado óptimo. Se caracteriza por tener el potencial de generar soluciones de diseño muy difícilmente alcanzables por la mente humana mediante procesos analíticos de diseño. [3]

Dentro del diseño generativo se pueden distinguir dos etapas muy distintivas. La primera etapa es la **parametrización** del problema de diseño. Acá se establecen todas las variables que definen el diseño final, así como las restricciones que lo gobiernan. Es muy común la utilización de softwares o plataformas CAD para realizar la parametrización. Este proceso es analítico y de él depende gran parte de la solución final. [3]




Figura 2.12: Parametrización CAD para el de diseño (a) parlantes y (b) motocicletas [11]

La segunda etapa corresponde al proceso iterativo o evolutivo, mediante el cual el algoritmo busca las soluciones al problema. Este proceso suele llevarse a cabo mediante codificación evolutiva, como por ejemplo los **algoritmos genéticos**. Es en esta etapa en donde se exploran y evalúan las distintas combinaciones posibles de parámetros para generar resultados de diseño. [5]




Figura 2.13: Soluciones de diseño generados mediante diseño generativo para (a) parlantes y (b) motocicletas [6]

2.5. Algoritmos genéticos

Los algoritmos genéticos (GA, por sus siglas en inglés) o programación evolutiva corresponden a un método iterativo inspirado en las ideas de mutación y selección natural de la teoría neo-Darwiniana. Estos algoritmos buscan emular el método mediante el cual las especies evolucionan con el correr de las generaciones para adaptarse de mejor manera al medio que los rodea, con el objetivo de resolver distintos problemas. [10]

A grandes rasgos, el funcionamiento de un GA para la resolución de un problema puede ser descrito mediante los siguientes pasos:

- Generación aleatoria de un número determinado de candidatos a solución, al cual se le denomina población.
- Evaluación de cada uno de los individuos de una población. Se les asigna un puntaje (fitness) según su capacidad de resolver el problema en cuestión.
- Selección de un porcentaje de los individuos de mayor desempeño (elitism)
- Generación de una nueva población a partir de la combinación de los individuos previamente seleccionados (crossover).
- Aplicación mutaciones aleatorias a algunos individuos de la población (mutation).
- Repetición de todo el proceso hasta alcanzar el resultado deseado.

Existen conceptos de gran importancia a la hora de establecer un algoritmo genético.

1. **Genotipo:** Forma mediante la cual se codifica la información para generar un individuo.
2. **Cromosoma:** Conjunto de datos o variables que contiene toda la información para generar un individuo.
3. **Fenotipo:** Representación gráfica o física de un individuo.
4. **Elitism:** Tasa de selección de los individuos más aptos de una población.
5. **Crossover:** Tasa mediante la cual los individuos más aptos se combinan entre sí para generar nuevos individuos.
6. **Mutation:** Tasa de mutación aleatoria de los individuos de una población.
7. **Fitness:** Función mediante la cual se evalúa el desempeño de cada individuo de una población.
8. **Función objetivo:** Objetivo que se espera alcanzar con el algoritmos. Ejemplo: maximizar o minimizar el fitness.
9. **Generación:** Población que es generada en cada etapa iterativa.

Un GA termina su proceso iterativo cuando converge a una solución. Por ejemplo, si se desea alcanzar un fitness determinado, el algoritmo se detiene cuando un individuo de una generación alcanza el valor buscado. Sin embargo, existen casos en que el resultado óptimo es desconocido, es decir, no se conoce el valor de fitness al que se desea llegar. Uno de estos casos podría ser el maximizar el valor del fitness, sin conocer de antemano cuál es ese valor. En estos casos, se necesita un criterio para determinar si el algoritmo ha convergido a la solución óptima o si aún faltan iteraciones para alcanzar el objetivo. Para ello, se utilizan las denominadas curvas de aprendizaje. Estas curvas representan la evolución del fitness de una población a medida que avanzan las generaciones. [8]

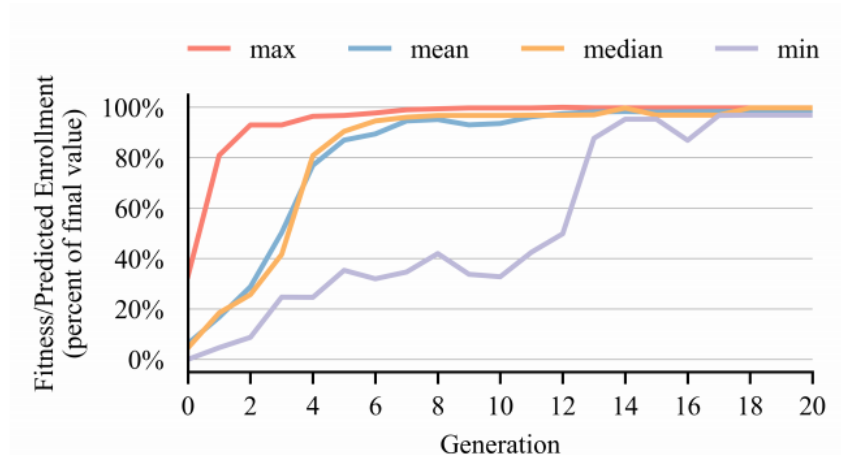


Figura 2.14: Ejemplo de curva de aprendizaje, evolución del fitness hasta alcanzar convergencia [8]

Se establece que cuando las curvas de fitness máximo y fitness promedio de una población convergen en una meseta hasta un valor muy cercano, el algoritmo ha alcanzado una solución óptima y el proceso puede ser detenido. El proceso puede seguir hasta que incluso el fitness mínimo de una población también converja, pero no es una condición necesaria.

Capítulo 3

Metodología

3.1. Creación del genotipo

Para generar el genotipo se utiliza Grasshopper, una plataforma de diseño paramétrico y de programación visual incluida en el software Rhinoceros 6.0. Esta plataforma permite generar un código al mismo tiempo que genera una representación visual del fenotipo, lo que permite detectar rápidamente errores y visualizar el resultado de la codificación en tiempo real.

Se genera un genotipo para estructuras del tipo reentrantes. Para ello, se comienza con los parámetros más básicos. El primero es el tamaño, este parámetro representa el largo de la arista de la matriz cuadrada en centímetros. Toma valores enteros entre 10 y 30.

Dado que tanto la matriz como las celdas diseñadas son cuadradas, solo se admiten configuraciones con igual número de celdas a lo largo y ancho. Es así como se constituye el segundo parámetro del genoma, el número de celdas. Éste toma valores enteros entre 3 y 6 y representa la cantidad de celdas que constituyen la matriz a lo largo y ancho. Un valor de 4 representa una matriz de 4x4 celdas unitarias.

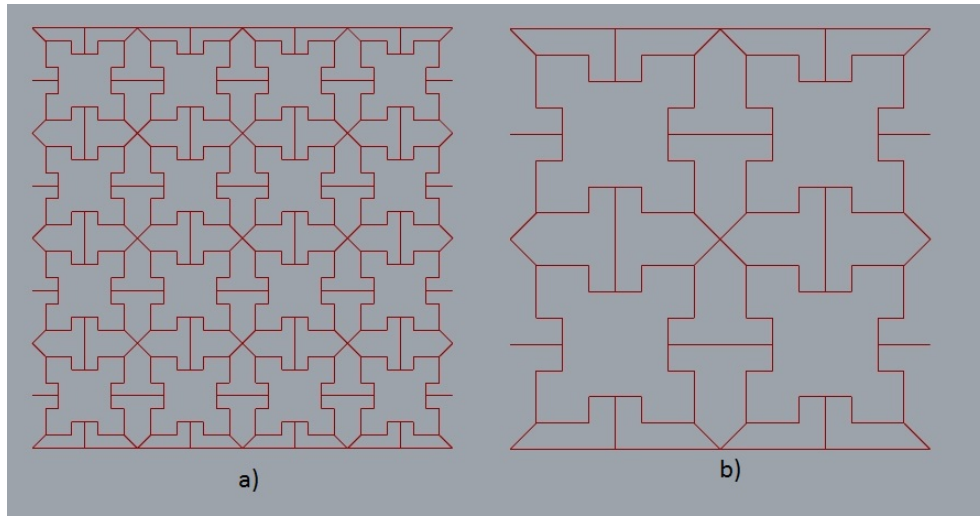


Figura 3.1: Matrices con distintos números de celdas. (a) Matriz de 4x4 celdas. (b) Matriz de 2x2 celdas

Para el diseño de la estructura en sí, se divide cada celda en 4 cuadrantes. Se realiza un diseño sobre uno de los cuadrantes y los restantes son completados por simetría. La simetría fue elegida tanto para simplificar el genoma, como para que las deformaciones sean simétricas y más fáciles de evaluar.

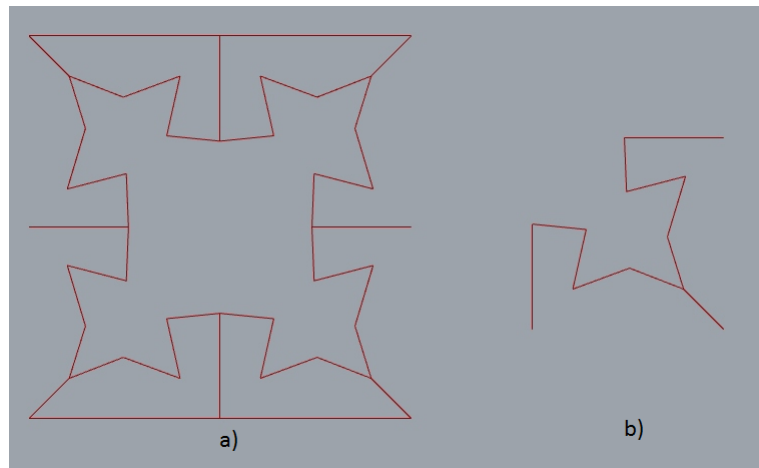


Figura 3.2: Estructura de una celda. (a) Celda completa. (b) Cuadrante de diseño

La estructura de cada celda requiere múltiples pasos. En primer lugar, se establecen segmentos para separar el cuadrante de diseño. Sobre estos segmentos, se generan puntos, los cuales se nombran puntos externos. La posición de cada punto externo queda determinada por un parámetro real, con dos decimales, que pertenece al intervalo $[0,1]$. Los valores 0,00 y 1,00 representan los extremos del segmento, 0,50 representa la mitad, 0,25 representa un cuarto y así sucesivamente. Estos parámetros (cuatro en total) se denominan parámetros de posición y forman parte del cromosoma.




Figura 3.3: Parametrización de puntos externos. (a) Segmentos que determinan el cuadrante de diseño. (b) Puntos externos (verde) con parámetros de posición = 0.5. (c) Punto externo (verde) con parámetro de posición = 0.1

Posteriormente, desde los puntos externos y desde 3 de las 4 esquinas del cuadrante, se trazan segmentos hasta el centro del cuadrante. La esquina superior izquierda del cuadrante es omitida en esta etapa, ya que esta esquina representa el centro de la celda. Para que la celda pueda presentar un comportamiento auxético, necesita poseer un centro "Vacío" hacia donde converger (en caso de compresión) o desde donde expandirse (en caso de tracción). Sobre estos segmentos, se generan nuevos puntos (7 en total) los cuales se denominan puntos internos. La posición de cada punto interno respecto al segmento al que pertenece queda determinada por un parámetro de posición. Estos 7 nuevos parámetros de posición forman parte del cromosoma.

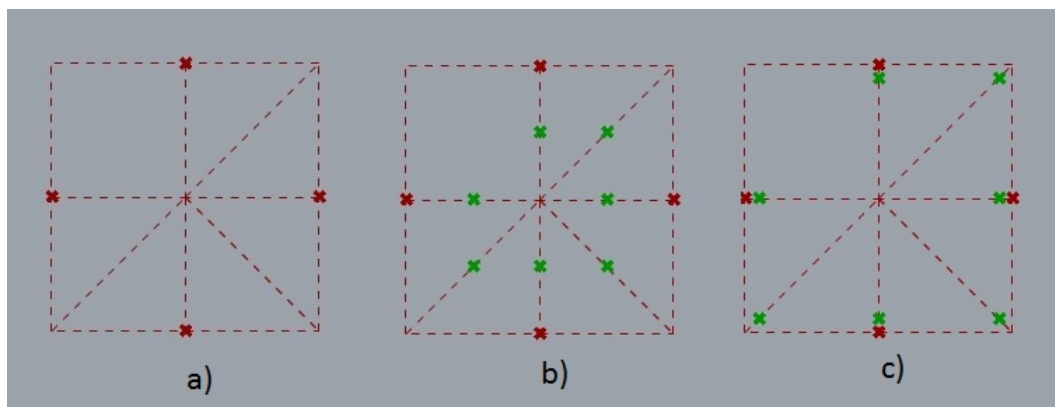


Figura 3.4: Parametrización de puntos internos. (a) Segmentos hacia el centro del cuadrante. (b) Puntos internos (verde) con parámetros de posición = 0.5. (c) Puntos internos (verde) con parámetros de posición = 0.1

Es en esta etapa en donde se comienza a generar la estructura propiamente tal. En primer lugar, se conectan los puntos internos uno por uno, en sentido horario, de tal forma que ninguna de estas conexiones interfiera con otra. Para que exista continuidad en todo el diseño, debe existir continuidad con los otros cuadrantes, por ende, se añaden dos segmentos que aseguren esta condición, ambos hasta los puntos externos ubicados en los ejes de simetría. Finalmente, se agregan segmentos que aseguren continuidad con otras celdas dentro de la matriz.

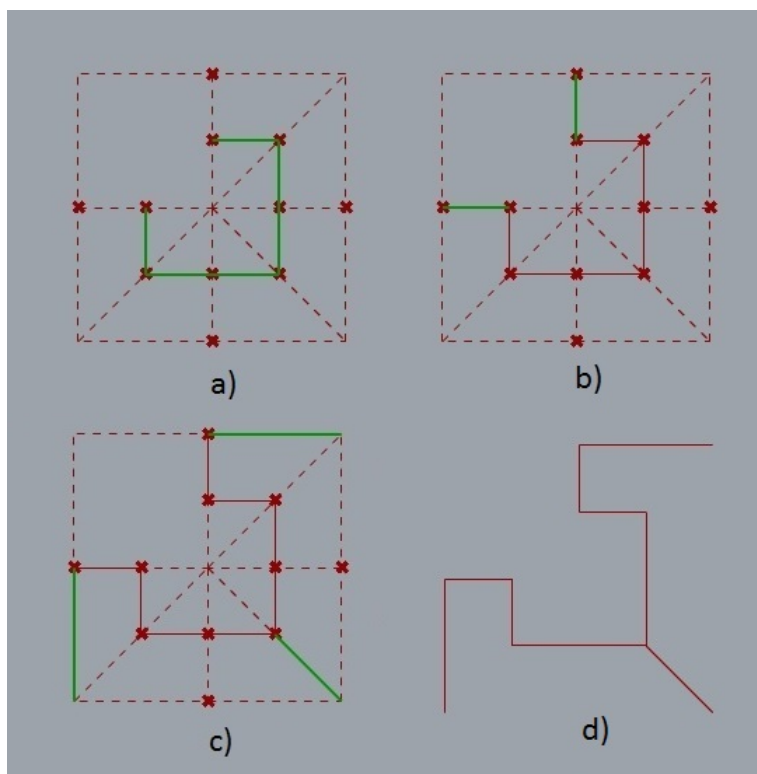


Figura 3.5: Generación de la estructura de la celda. (a) Unión (verde) de puntos internos. (b) Continuidad con el resto de la celda (verde). (c) Continuidad con otras celdas. (d) Estructura del cuadrante final.

Finalmente, una vez generada una celda completa, se genera la matriz del metamaterial. A esta matriz se le añaden estructuras horizontales en la parte superior e inferior, siendo estas las superficies de contacto que estarán sometidas a las fuerzas de tracción y de compresión.

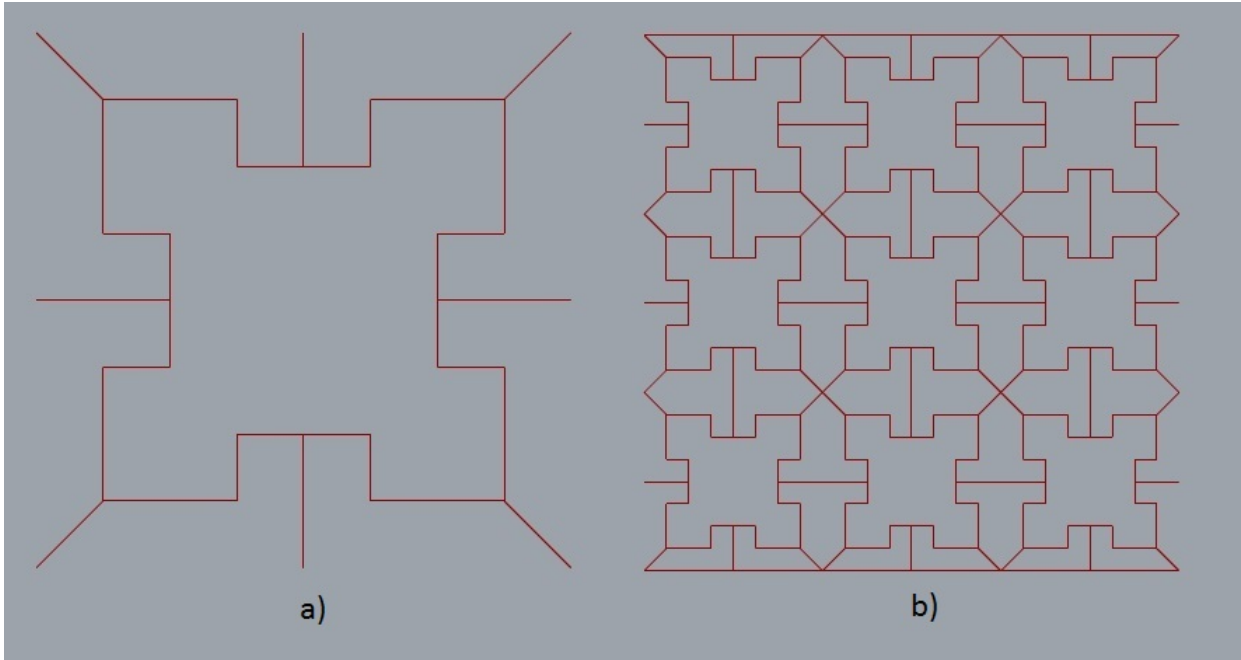


Figura 3.6: Estructura final del metamaterial. (a) Celda unitaria completa. (b) Matriz de 3x3, con estructuras horizontales en la parte superior e inferior.

Es así como la estructura del metamaterial queda parametrizada por trece variables en total. Una variable de tamaño, una variable de cantidad de celdas por matriz, cuatro parámetros de posición para los puntos externos y siete parámetros de posición para los puntos internos.

3.2. Evaluación del fenotipo

Para evaluar la deformación de los individuos, se utiliza el plugin Karamba 3D de Grasshopper, el cual utiliza análisis de elementos finitos para calcular las deformaciones de estructura de tipo enrejados.

La matriz es sometida a una deformación controlada desde el borde superior. Dicha deformación, ya sea de compresión o de tracción, ocurre en dirección del eje y es uniforme respecto al eje x . Como condiciones de borde, se imponen apoyos simples a lo largo de los segmentos superior e inferior. Este proceso se encuentra representado en la Figura 3.7 para un caso de compresión.




Figura 3.7: Matriz sometida a deformación. Fuerza de deformación (flechas rojas) y apoyos simples (verde).

Se requiere la deformación longitudinal y transversal para obtener el coeficiente de Poisson. Para la deformación longitudinal, se utiliza la diferencia entre el alto inicial de la matriz y el alto final una vez ocurrida la deformación. Dado que la deformación es constante a lo largo del eje x , este valor es único y fácilmente medible. Para ello, se toman en cuenta los puntos externos de la estructura correspondientes a las aristas superior e inferior de la matriz cuadrada.

En cambio, para calcular la deformación transversal, se utilizan los puntos más externos de la matriz, tanto por el lado izquierdo como por el lado derecho. En primer lugar, se mide la distancia entre los puntos que posean la misma coordenada y . Estas medidas son realizadas para calcular un promedio de distancias. Este promedio representa el ancho inicial de la matriz. Este proceso se repite una vez realizada la deformación para obtener el ancho final de la matriz. Es pertinente mencionar que las esquinas de la matriz se excluyen de este proceso, ya que, por condiciones de borne, estos puntos siempre mantendrán la misma coordenada y (no poseen variaciones en su coordenada x). La Figura 3.8 ilustra el proceso mediante el cual se realizan estas medidas.

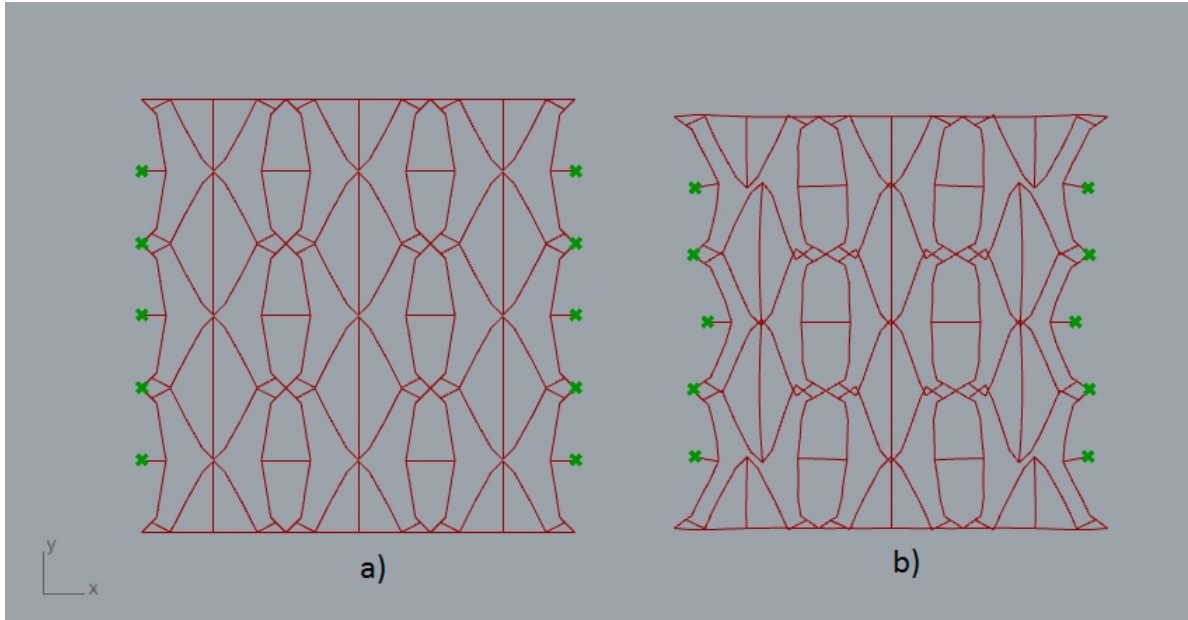


Figura 3.8: Puntos utilizados para medir longitud transversal. (a) Largo inicial (pre-compresión). (b) Largo final (post-compresión).

3.3. Fitness y función objetivo

Se establecen 2 funciones fitness distintas, las cuales serán utilizadas según el objetivo que se desee alcanzar. La primera corresponde al coeficiente de Poisson multiplicado por -1. Esta función se define de esta manera para los Poisson Ratio más negativos arrojen un mayor valor de fitness. Esta función es utilizada para encontrar las estructuras más auxéticas posibles. Para ello, se establece como función objetivo el maximizar el fitness.

Definición 3.1 *Función fitness N°1*

$$f = -\nu$$

Definición 3.2 *Función objetivo N°1*

$$\text{Max } f$$

Por otro lado, se establece otra función, la cual tiene como objetivo que el algoritmo genere estructuras que posean un Poisson ratio específico. Esta función busca encontrar soluciones que, sin ser las más auxéticas, posean un coeficiente específico predeterminado. Es así que este fitness se define como el valor absoluto de la diferencia entre el Poisson Ratio objetivo y el medido.

Definición 3.3 *Función fitness N°2*

$$\text{fitness} = \|\nu_{obj} - \nu\|$$

En este caso, se establece como función objetivo minimizar el fitness.

Definición 3.4 *Función objetivo N°2*

$$\text{Min } f$$

3.4. Proceso evolutivo

El proceso evolutivo es llevado a cabo mediante el plugin Octopus de la plataforma Grasshopper. La tabla 3.1 muestra los parámetros utilizados para el GA. Estos parámetros se mantienen constantes y no varían en ninguno de los casos de estudio. Estos parámetros fueron elegidos por recomendación de la herramienta de software utilizada.

Tabla 3.1: Parámetros utilizados en el GA.

Population size	100
Elitism	0.5
Mutation Rate	0.2
Crossover Rate	0.8
Min. Generations	20

El proceso de evolutivo se inicia al establecer una deformación, ya sea de tracción o de compresión. Este es el parámetro de entrada. Un valor positivo representa tracción, mientras que un valor negativo representa compresión. Por ejemplo, una entrada de 0.05 representa una tracción del 5%.

Dado que solo se evalúan metamateriales de dimensión 10x10 centímetros y 3x3 celdas unitarias, estos parámetros (pertenecientes al cromosoma) se establecen como fijos y no forman parte de las variables con las que trabaja el GA.

El método mediante el cual se determina la convergencia del GA, y por ende el fin de éste, varía según la función objetivo utilizada. Cuando se busca maximizar la auxeticidad (Función objetivo N°1), dado que no se conoce el valor óptimo, se utilizan las curvas de aprendizaje del GA. En particular, se detiene el algoritmo cuando las curvas del fitness máximo (Max. Fitness) y fitness promedio (Avrg.Fitness) alcanzan una meseta constante, con valores muy cercanos entre sí. Este comportamiento debe ocurrir por lo menos por 4 generaciones para considerarse como caso exitoso.

Por otro lado, cuando se desea llegar a un Poisson Ratio específico (por lo tanto el fitness óptimo es conocido e igual a 0), el algoritmo se detiene habiéndose alcanzado un mínimo de 20 generaciones y un fitness tal que $fitness < 0.001$. Se considera que dicho umbral representa una diferencia despreciable y que cualquier solución que alcance dicho valor se considera como óptima.

3.5. Casos de estudio

3.5.1. Tracción

Se establecen 5 casos distintos en los que se somete el metamaterial a tracción. Los casos se diferencian entre sí por el porcentaje de deformación al que son sometidos. Éstos se detallan en la tabla 3.2. Se establece el 15 % de tracción como límite, debido a que valores más grandes provoca que en algunas simulaciones la estructura se rompa y el algoritmo se detenga sin arrojar un resultado óptimo.

Tabla 3.2: Casos de estudio en tracción.

Caso N°	Tracción [%]
1	3
2	6
3	9
4	12
5	15

Para cada caso de estudio, se realizan dos procesos evolutivos. El primero busca generar la estructura con Poisson Ratio más negativo posible. Para ello, se los individuos son evaluados con la función fitness N°1 y se utiliza la función objetivo N°1 para correr el algoritmo.

Una vez alcanzado el valor óptimo, se elige de forma arbitraria un Poisson Ratio menos negativo al valor encontrado en el proceso anterior y se establece como ν_{obj} . Teniendo este valor, los individuos son evaluados con la función fitness N°2 y se utiliza la función objetivo N°2 para correr el algoritmo. El resultado es una estructura que posee un Poisson Ratio casi idéntico al valor impuesto en ν_{obj} .

3.5.2. Compresión

De forma análoga a los casos de tracción, el metamaterial es sometido a 4 casos de compresión, los cuales se diferencian entre sí por el porcentaje de deformación aplicado. Los casos pueden ser observados en la tabla 3.3.

Tabla 3.3: Casos de estudio en Compresión.

Caso N°	Compresión [%]
6	3
7	6
8	9
9	12

De igual forma, se realizan dos procesos evolutivos. El primero busca generar la estructura con Poisson Ratio más negativo posible. Una vez alcanzado dicho valor, se elige de forma

arbitraria un coeficiente menos negativo al valor encontrado en el proceso anterior y se inicia otro GA, esta vez con el objetivo de generar una estructura que posea dicho Poisson Ratio.

3.5.3. Doble objetivo

Con el fin de explorar más a fondo el potencial del método propuesto, se plantea un caso de estudio pretende generar estructuras que puedan ser solución a dos objetivos de forma simultánea, o en su defecto, generar soluciones que se acerquen lo más posible al resultado deseado. Para ello, los individuos serán evaluados con la función fitness N°2 y se someterán a simulaciones de compresión y tracción de forma simultánea. La tabla 3.4 muestra los dos objetivos que se persiguen simultáneamente en este caso.

Tabla 3.4: Parámetros de entrada y objetivos buscados

Objetivo N°1	Entrada	Tipo de entrada	Poisson Ratio Obj.
1	0.06	Tracción	-0.6
2	-0.06	Compresión	-0.6

Capítulo 4

Resultados

4.1. Casos de tracción

La tabla 4.1 presenta el resumen de los resultados obtenidos en la primera etapa del proceso evolutivo, la cual genera las estructuras con mayor auxeticidad posible. Se detallan las medidas obtenidas para el ancho promedio y el ancho en el centro de las estructuras generadas, con el fin de darle mayor profundidad al posterior análisis.

Tabla 4.1: Resumen de resultados, primera parte. Búsqueda de máxima auxeticidad.

Caso N°	Poisson Ratio	Ancho promedio [cm]	Ancho en el centro [cm]
1	-1.119	10.34	10.62
2	-0.783	10.47	10.91
3	-0.731	10.66	10.93
4	-0.643	10.77	11.44
5	-0.543	10.8	11.43

La tabla 4.2 muestra los valores de Poisson Ratio que fueron escogidos para realizar esta segunda parte. Dichos valores nacen de los obtenidos en la parte anterior, ya que son todos menores en módulo. Se presentan los resultados a los que converge el algoritmo y la diferencia existente entre ambos valores.

Tabla 4.2: Resumen de resultados, segunda parte. Búsqueda de Poisson Ratio específicos.

Caso N°	Poisson Ratio Obj.	Poisson Ratio	Diferencia
1	-0.6	-0.59996	-4.00E-05
2	-0.5	-0.50002	2.00E-05
3	-0.6	-0.5994	-6.00E-04
4	-0.3	-0.30001	1.00E-05
5	-0.4	-0.3984	-1.60E-03

La figura 4.1 grafica los datos presentados anteriormente en la tabla 4.1, con el objetivo de profundizar su análisis

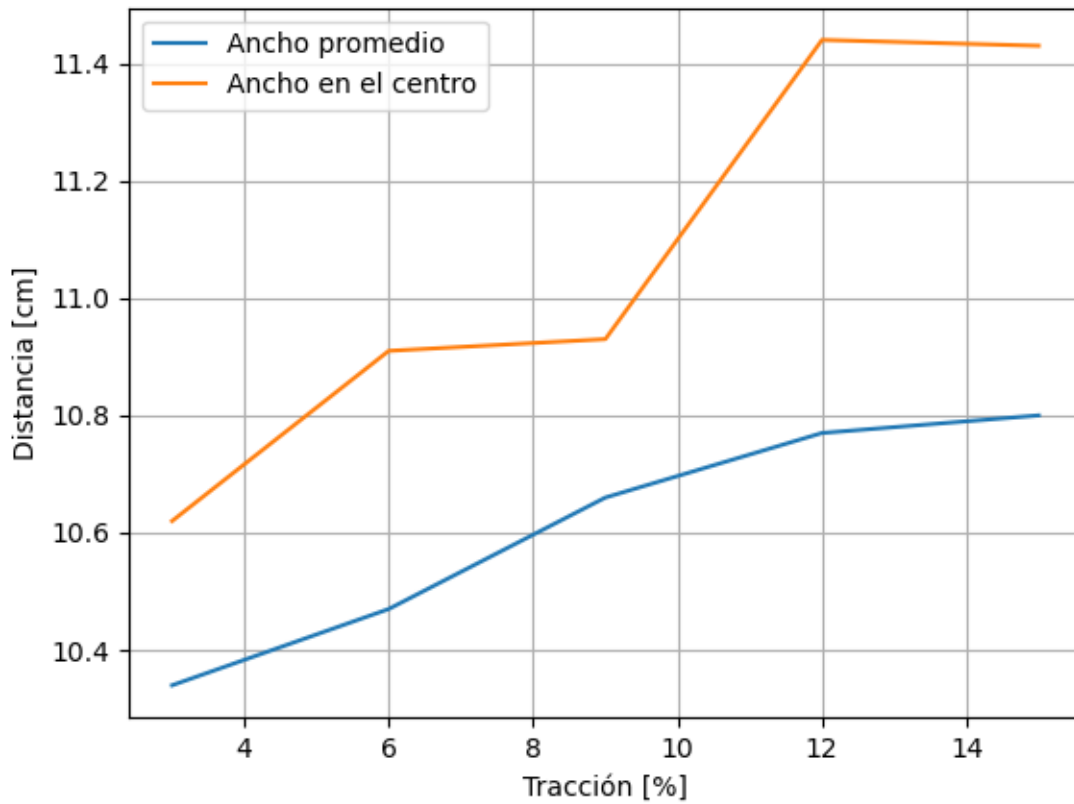


Figura 4.1: Dimensiones de las estructuras generadas para distintos porcentajes de tracción, caso de máxima auxeticidad.

4.1.1. Estructuras generadas

Se presentan a continuación todas las estructuras resultantes de los casos de estudio anteriormente descritos. Cada estructura es presentada en su forma natural, sin estar sujeta a ninguna deformación, así como en su forma deformada tras ser sometida a tracción.

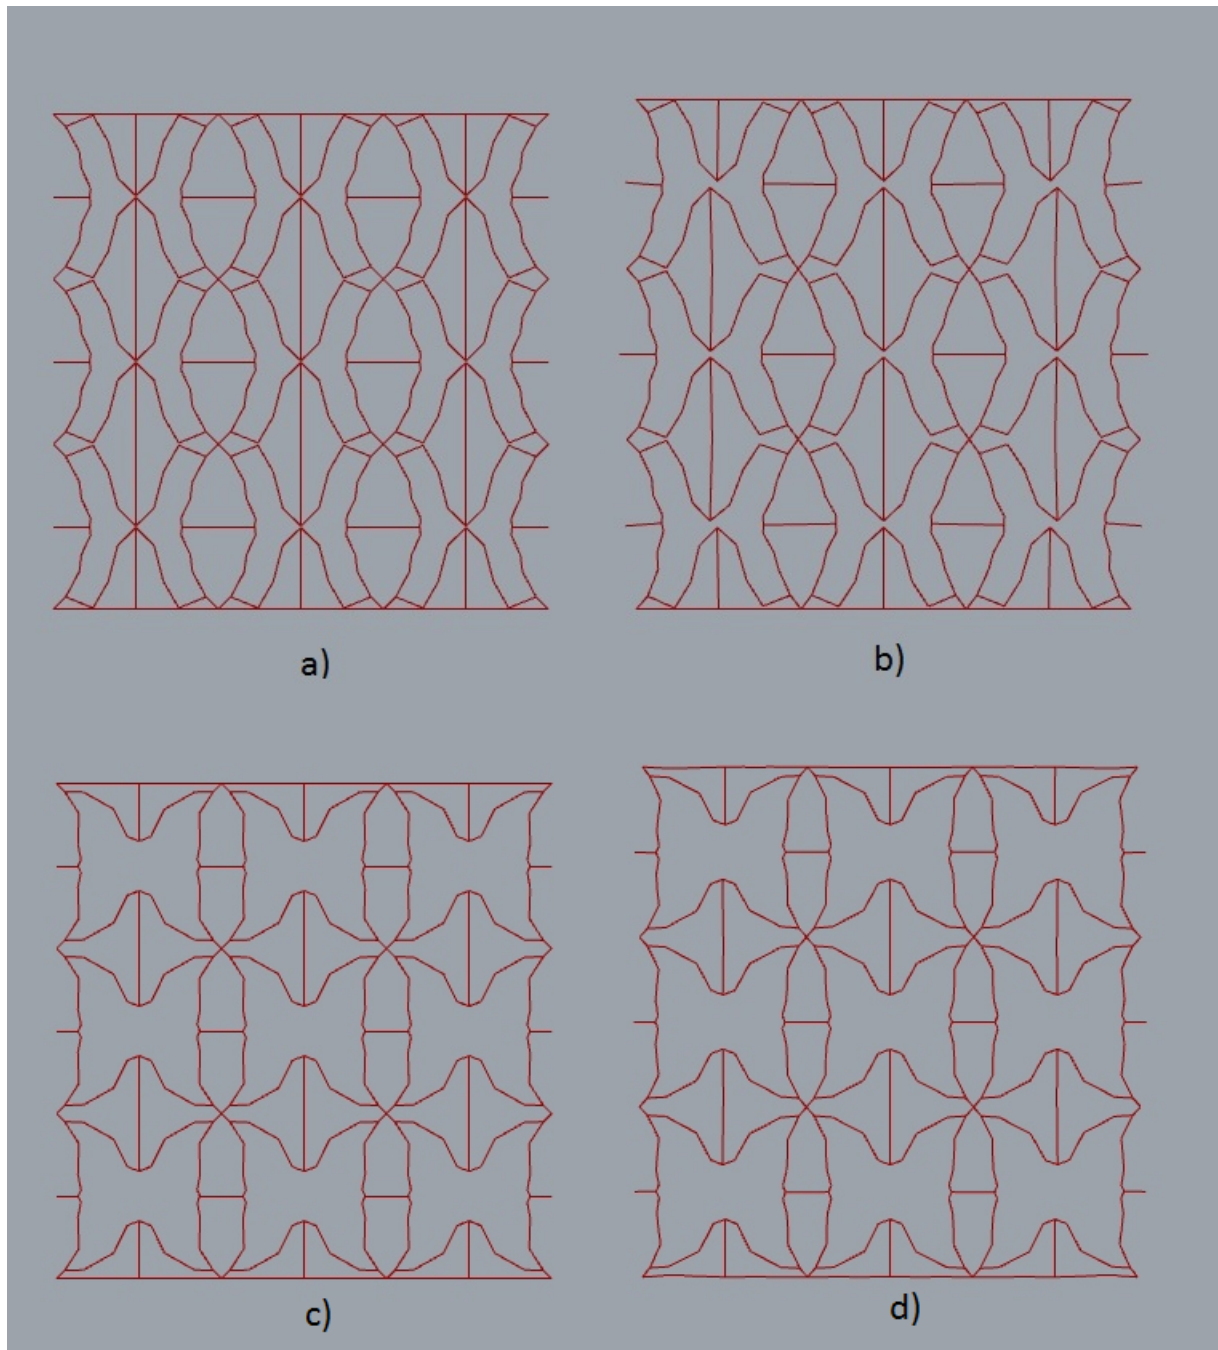


Figura 4.2: Fenotipos obtenidos para caso N°1. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.6. (d) Estructura con Poisson Ratio = -0.6 en tracción.

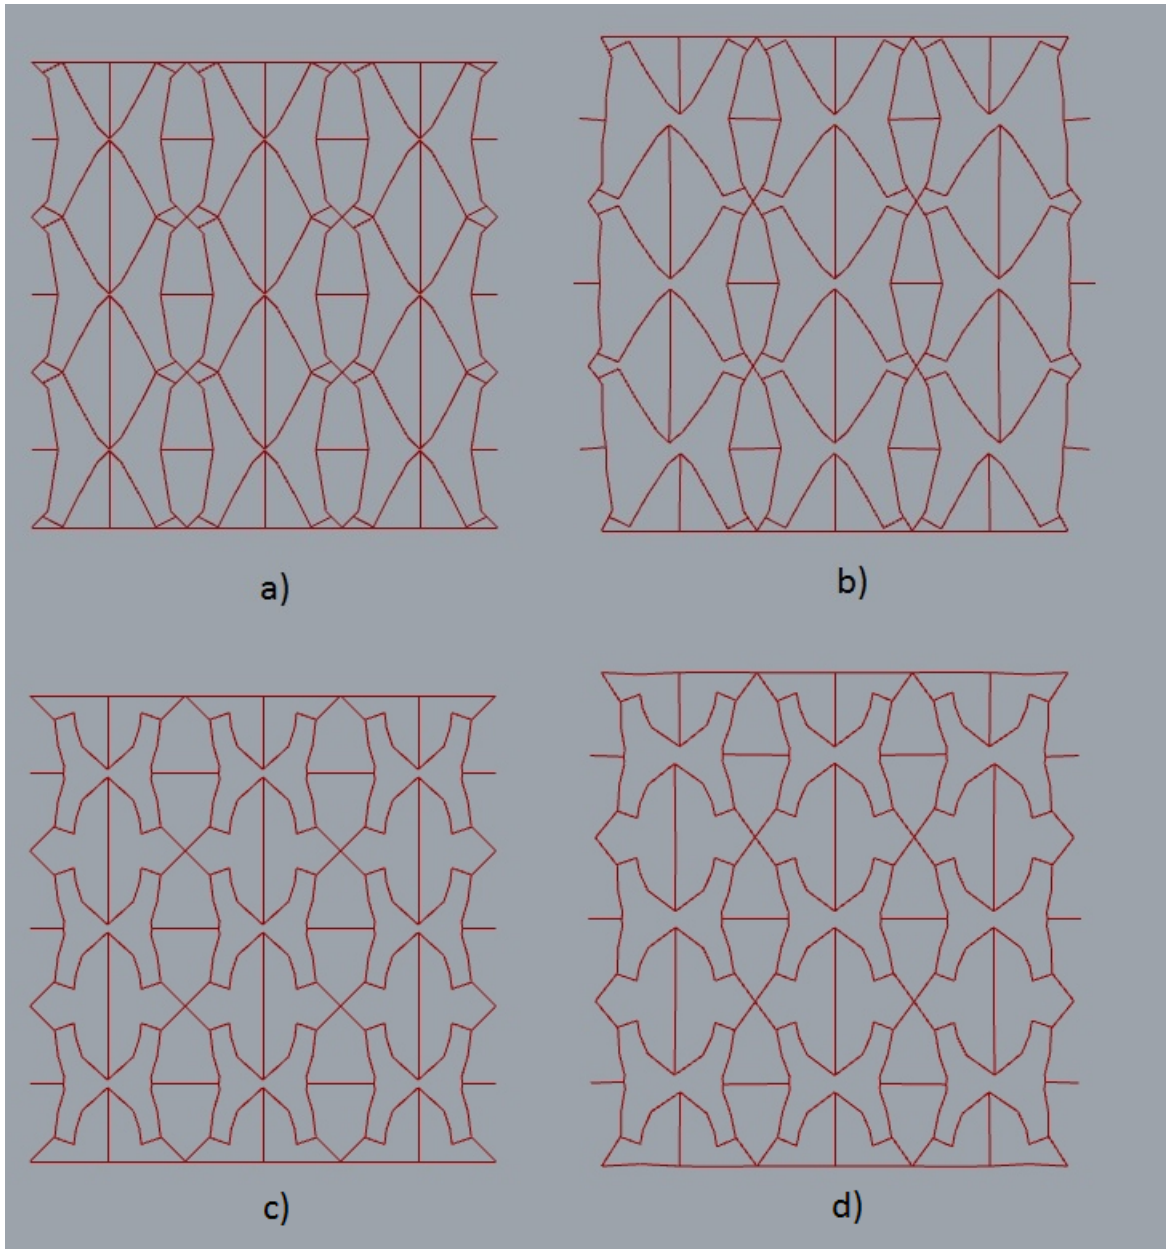


Figura 4.3: Fenotipos obtenidos para caso N°2. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.5. (d) Estructura con Poisson Ratio = -0.5 en tracción.




Figura 4.4: Fenotipos obtenidos para caso N°3. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.6. (d) Estructura con Poisson Ratio = -0.6 en tracción.

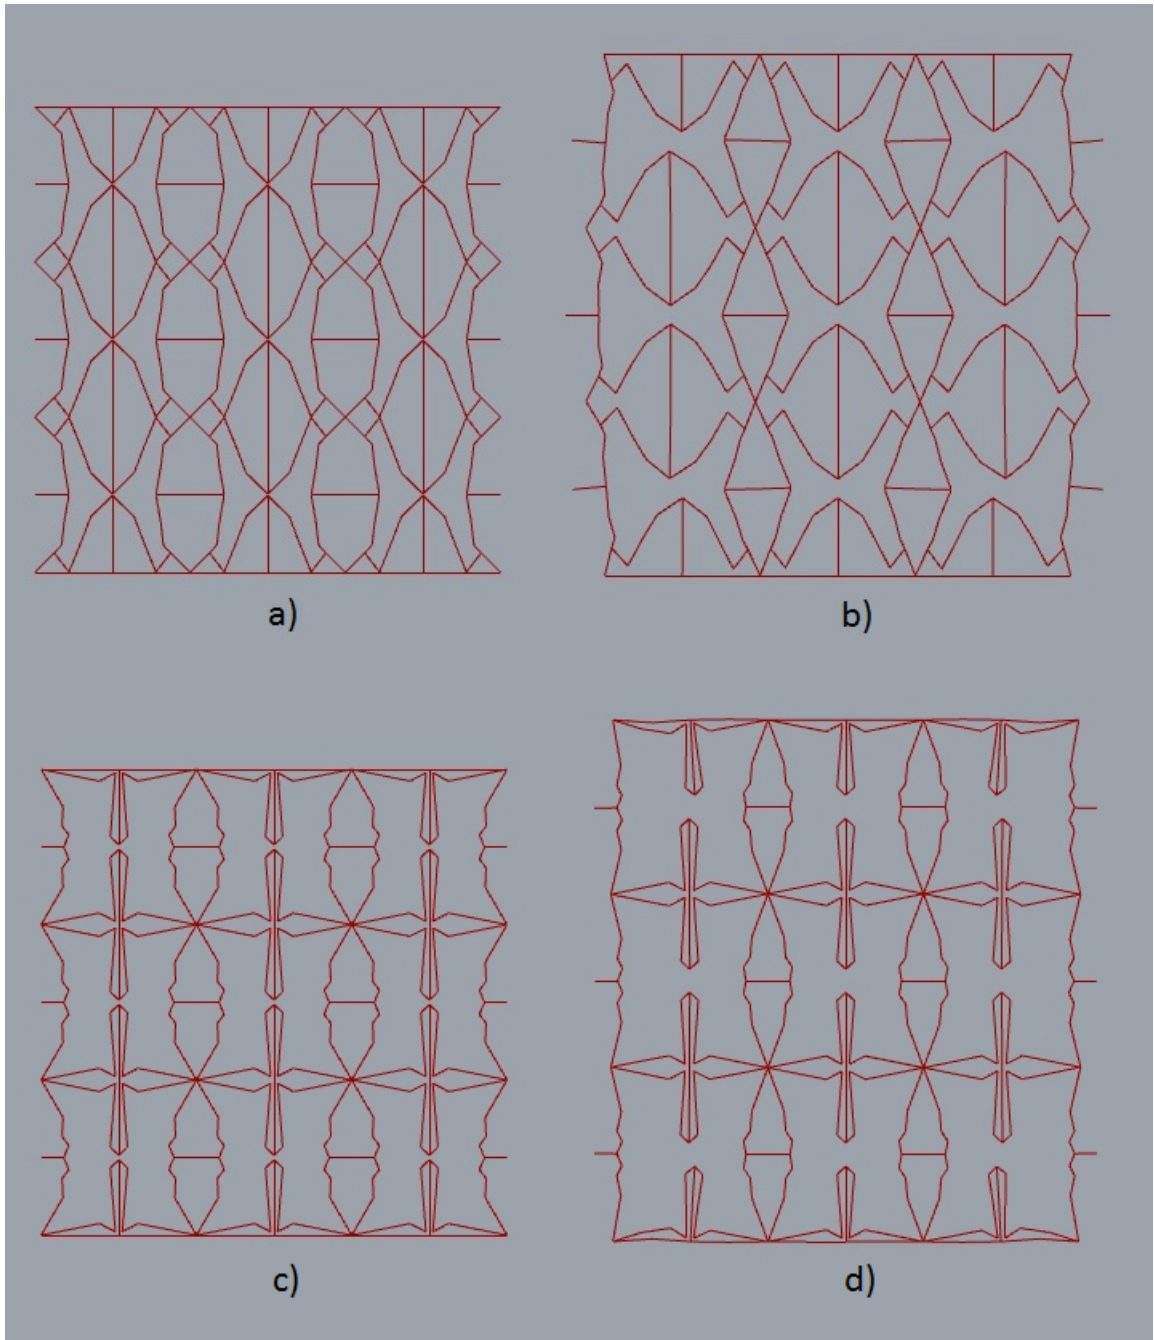


Figura 4.5: Fenotipos obtenidos para caso N°4. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.3. (d) Estructura con Poisson Ratio = -0.3 en tracción.

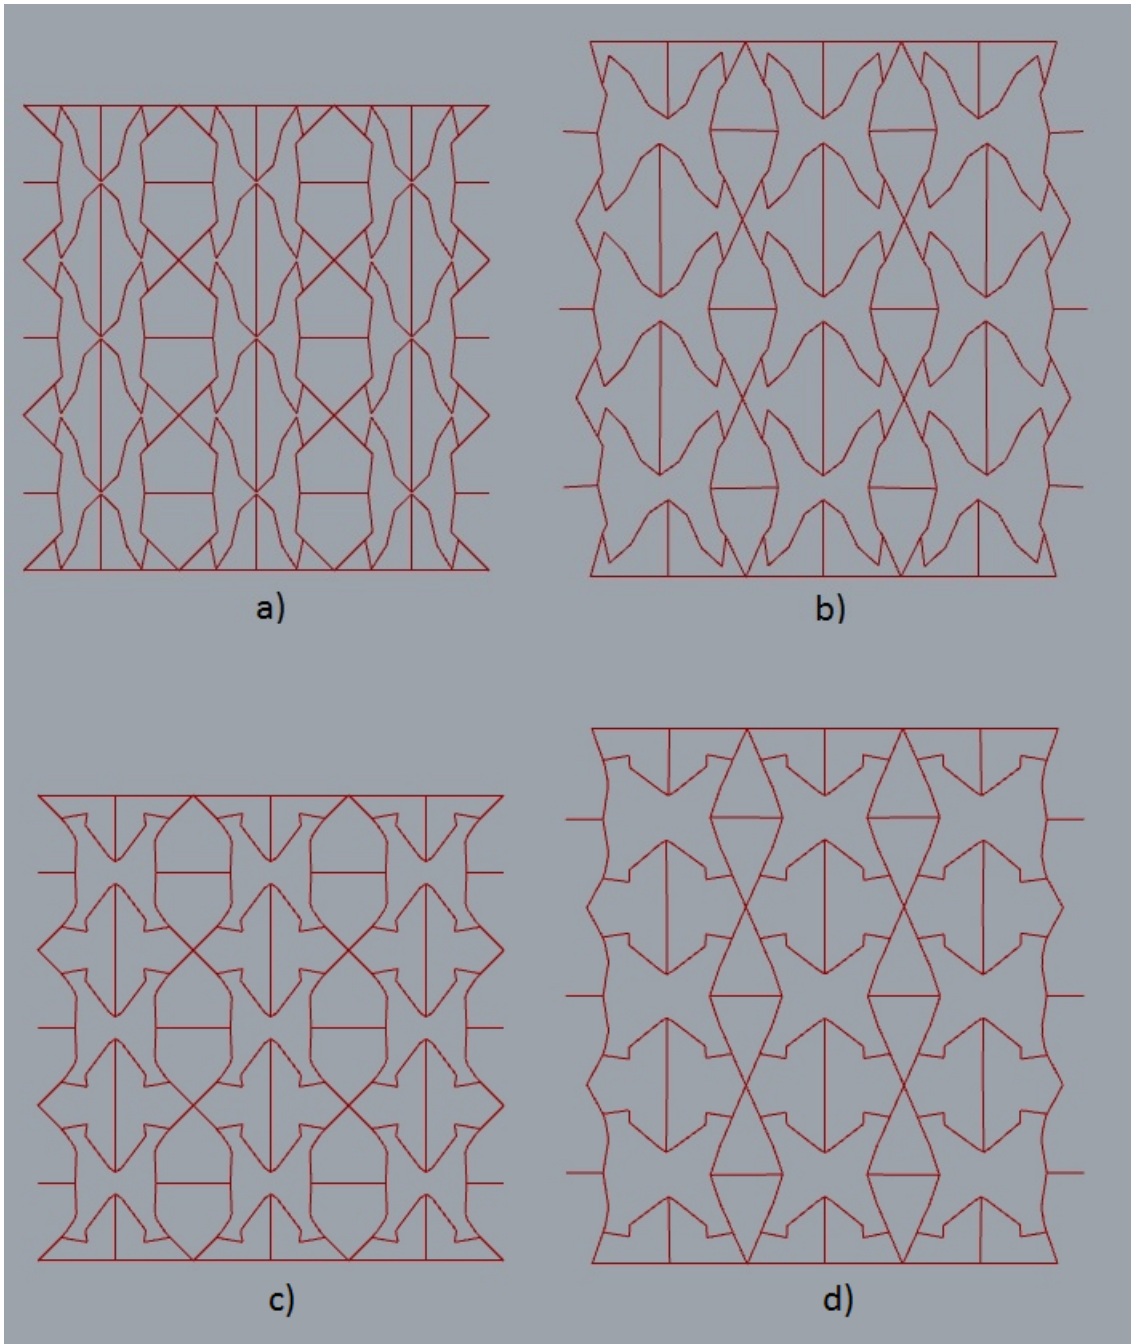


Figura 4.6: Fenotipos obtenidos para caso N°5. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.4. (d) Estructura con Poisson Ratio = -0.4 en tracción.

4.1.1.1. Curvas de aprendizaje




Figura 4.7: Curva de aprendizaje caso N°1, máxima auxeticidad




Figura 4.8: Curva de aprendizaje caso N°2, máxima auxeticidad

Curva de aprendizaje tracción de 9%,
caso de máxima auxeticidad




Figura 4.9: Curva de aprendizaje caso N°3, máxima auxeticidad

Curva de aprendizaje tracción de 12%,
caso de máxima auxeticidad




Figura 4.10: Curva de aprendizaje caso N°4, máxima auxeticidad




Figura 4.11: Curva de aprendizaje caso N°5, máxima auxeticidad




Figura 4.12: Max. Fitness versus generaciones caso N°1, Poisson Ratio = -0.6

Convergencia fitness caso Poisson ratio
objetivo, tracción de 6%




Figura 4.13: Max. Fitness versus generaciones caso N°2, Poisson Ratio = -0.5

Convergencia fitness caso Poisson ratio
objetivo, tracción de 9%




Figura 4.14: Max. Fitness versus generaciones caso N°3, Poisson Ratio = -0.6

Convergencia fitness caso Poisson ratio objetivo, tracción de 12%




Figura 4.15: Max. Fitness versus generaciones caso N°4, Poisson Ratio = -0.3

Convergencia fitness caso Poisson ratio objetivo, tracción de 15%




Figura 4.16: Max. Fitness versus generaciones caso N°5, Poisson Ratio = -0.4

4.2. Casos de compresión

La tabla 4.3 presenta el resumen de los resultados obtenidos en la primera etapa del proceso evolutivo, la cual genera las estructuras con mayor auxeticidad posible. Se detallan las medidas obtenidas para el ancho promedio y el ancho en el centro de las estructuras generadas, con el fin de darle mayor profundidad al posterior análisis.

Tabla 4.3: Resumen de resultados, primera parte. Búsqueda de máxima auxeticidad.

Caso N°	Poisson Ratio	Ancho Promedio [cm]	Ancho en el centro [cm]
6	-2.329	9.02	8.89
7	-1.923	8.65	8.68
8	-0.976	8.64	8.57
9	-0.897	8.62	8.72

La tabla 4.4 muestra los valores de Poisson Ratio que fueron escogidos para realizar esta segunda parte. Este proceso es análogo al realizado en los casos de tracción.

Tabla 4.4: Resumen de resultados, segunda parte. Búsqueda de Poisson Ratio específico.

Caso N°	Poisson Ratio Obj.	Poisson Ratio	Diferencia
6	-1.9	-1.89981	-1.90E-04
7	-1.2	-1.20002	2.00E-05
8	-0.6	-0,59996	-4.00E-05
9	-0.35	-0,35012	1.20E-04

La figura 4.17 muestra una representación gráfica de las dimensiones incluidas en la tabla 4.4

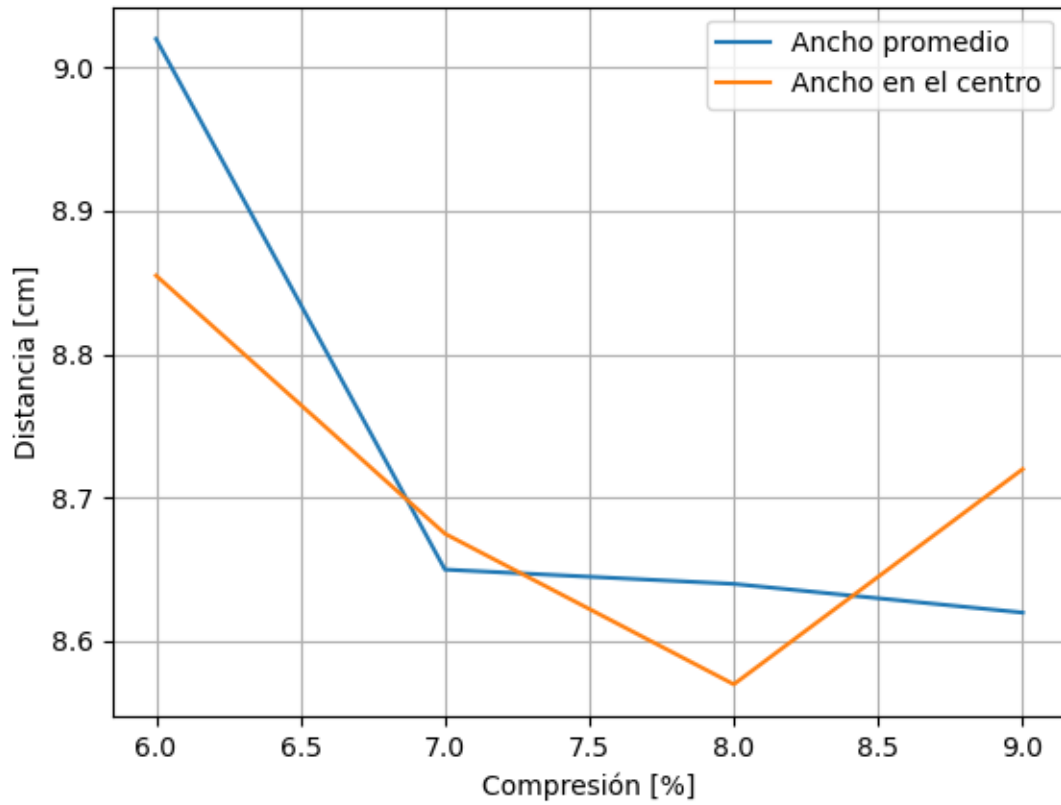


Figura 4.17: Dimensiones de las estructuras generadas para distintos porcentajes de compresión, caso de máxima auxeticidad.

4.2.1. Estructuras generadas




Figura 4.18: Fenotipos obtenidos para caso N°6. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -1.9. (d) Estructura con Poisson Ratio = -1.9 en tracción.

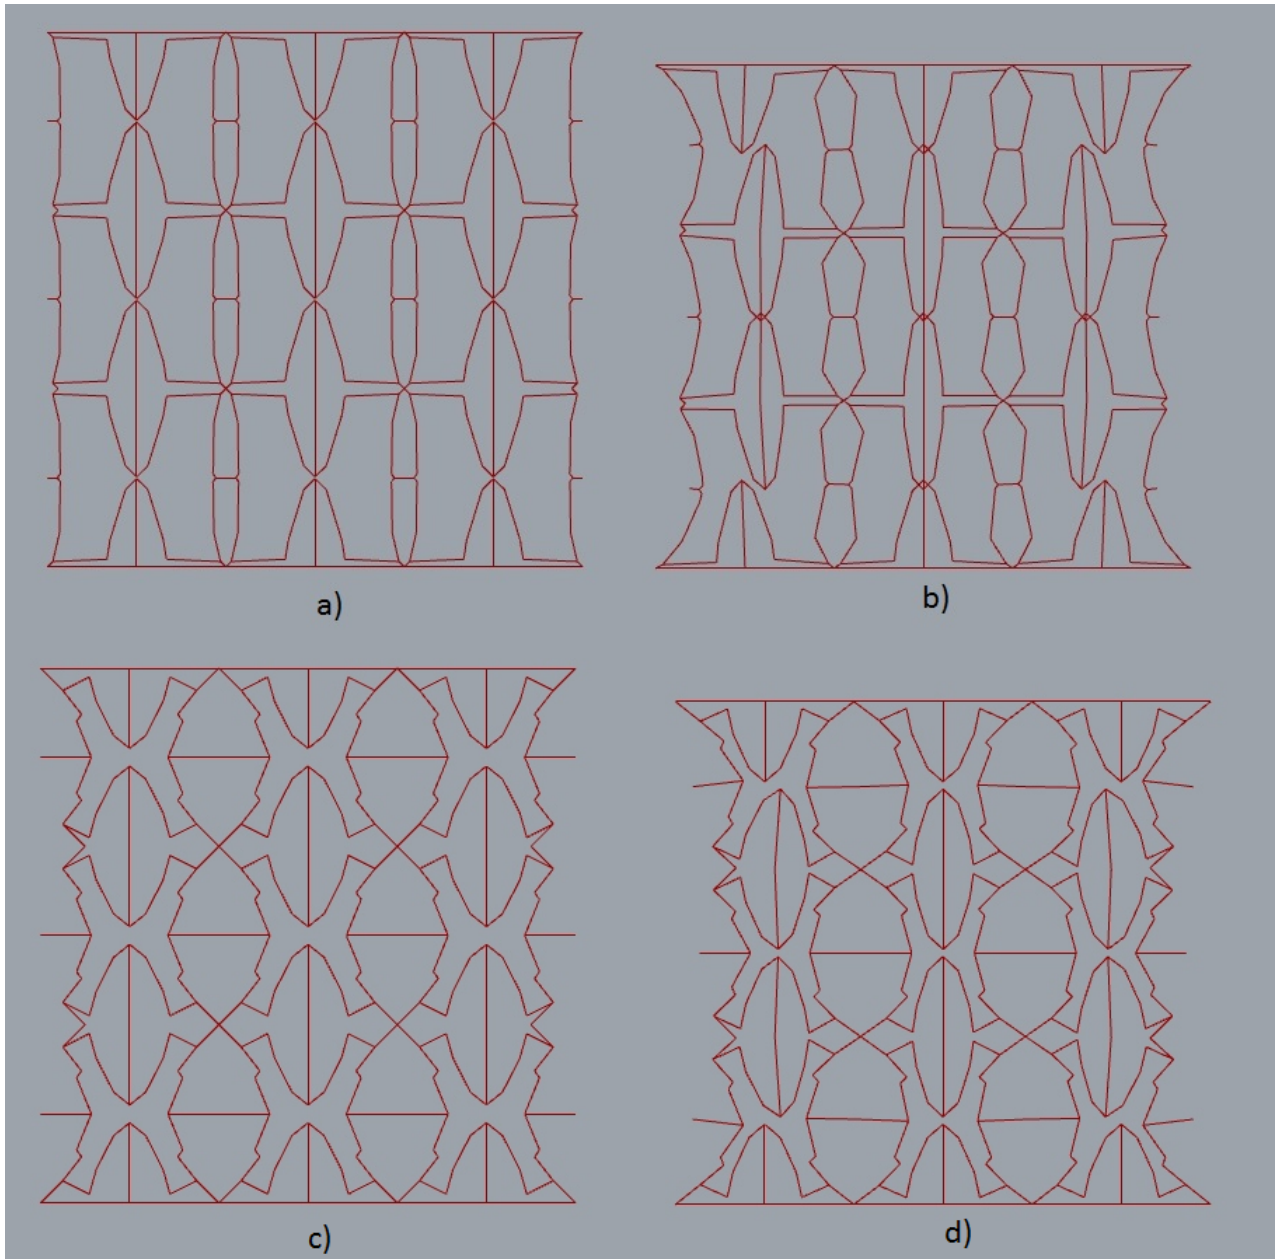


Figura 4.19: Fenotipos obtenidos para caso N°7. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -1.2. (d) Estructura con Poisson Ratio = -1.2 en tracción.




Figura 4.20: Fenotipos obtenidos para caso N°8. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.6. (d) Estructura con Poisson Ratio = -0.6 en tracción.

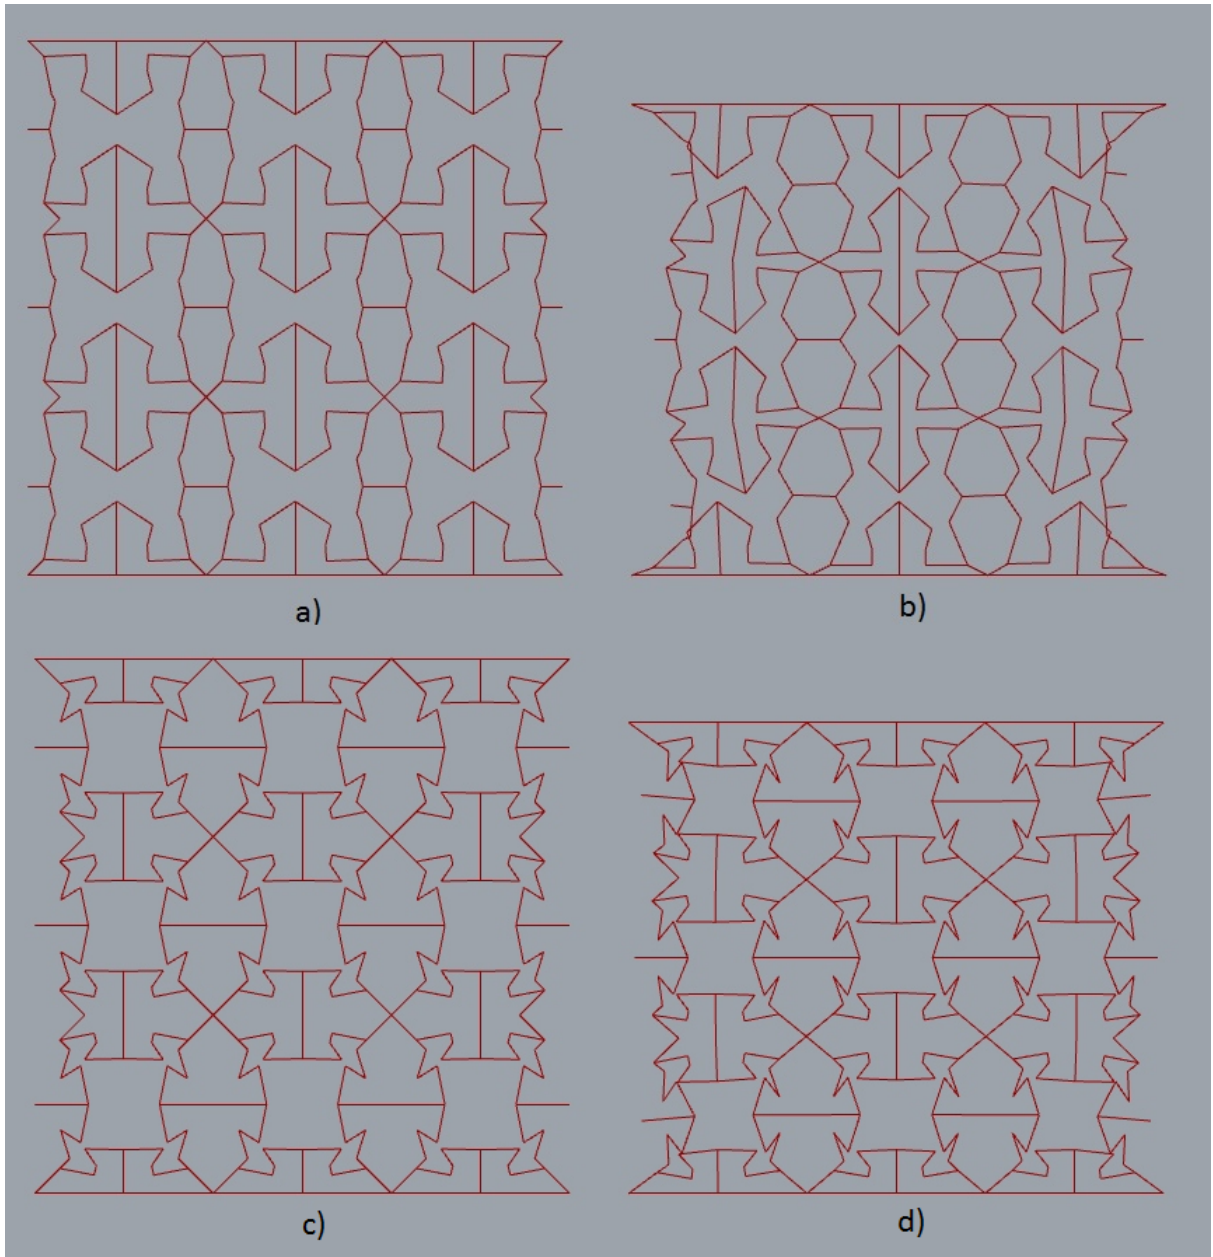


Figura 4.21: Fenotipos obtenidos para caso N°9. (a) Estructura más auxética. (b) Estructura más auxética en tracción. (c) Estructura con Poisson Ratio = -0.35. (d) Estructura con Poisson Ratio = -0.35 en tracción.

4.2.2. Curvas de aprendizaje




Figura 4.22: Curva de aprendizaje caso N°6, máxima auxeticidad




Figura 4.23: Curva de aprendizaje caso N°7

Curva de aprendizaje compresión de 9%,
caso de máxima auxeticidad




Figura 4.24: Curva de aprendizaje caso N°8

Curva de aprendizaje compresión de 12%,
caso de máxima auxeticidad




Figura 4.25: Curva de aprendizaje caso N°9

Convergencia fitness caso Poisson ratio objetivo, compresión de 3%

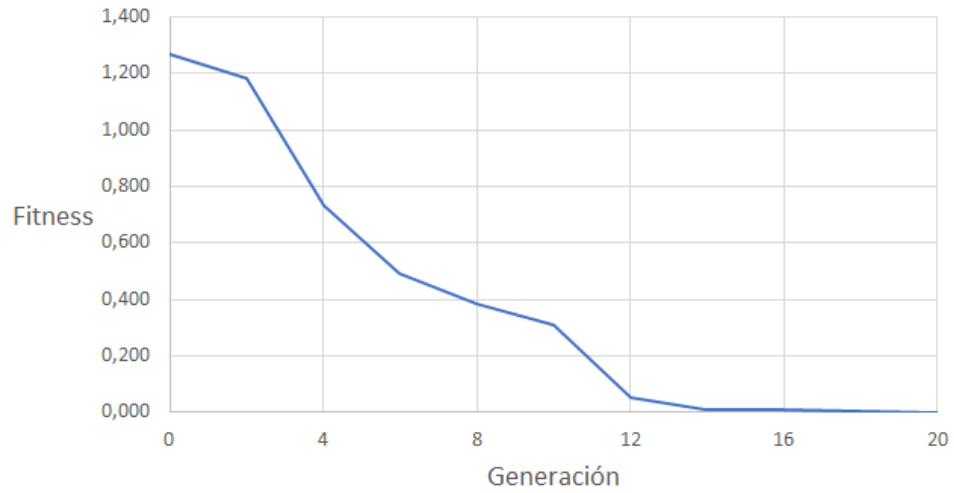


Figura 4.26: Max. Fitness versus generaciones, caso N°6, Poisson Ratio = -1.9

Convergencia fitness caso Poisson ratio objetivo, compresión de 6%




Figura 4.27: Max. Fitness versus generaciones, caso N°7, Poisson Ratio = -1.2

Convergencia fitness caso Poisson ratio objetivo, compresión de 9%




Figura 4.28: Max. Fitness versus generaciones, caso N°8, Poisson Ratio = -0.6

Convergencia fitness caso Poisson ratio objetivo, compresión de 12%




Figura 4.29: Max. Fitness versus generaciones, caso N°9, Poisson Ratio = -0.35

4.3. Doble objetivo

En la tabla 4.5 se presentan los valores obtenidos para ambos fitness por tres estructuras distintas. La primera estructura es el resultado que mejor optimiza el fitness del objetivo N°1, la segunda estructura es la que mejor optimiza el fitness N°2 y la tercera es la estructura que más se acerca a cumplir optimizar ambos fitness al mismo tiempo.

Tabla 4.5: Resumen de resultados para tres estructuras generadas por el algoritmo.

Estructura N°	Fitness N°1	Fitness N°2
1	0.0083	0.061
2	0.073	0.0003
3	0.025	0.038

4.3.1. Estructuras generadas

La Figura 4.30 muestra tres de las estructuras generadas como solución para optimizar el problema.




Figura 4.30: Fenotipos obtenidos para caso doble objetivo. (a) Estructura óptima para fitness N°1. (b) Estructura óptima para fitness N°2. (c) Estructura que más se acerca a ambos óptimos.

4.3.2. Curvas de aprendizaje

La Figura 4.31 muestra la evolución que tuvieron las curvas de fitness a lo largo de distintas generaciones.




Figura 4.31: Curvas de Fitness por generación, caso doble objetivo

Capítulo 5

Análisis y discusión

5.1. Tracción

A partir de la tabla 4.1 puede apreciarse como los grados máximos de auxeticidad obtenidos son mucho más elevados para deformaciones bajas, mientras que, a mayor deformación, menor es el Poisson Ratio obtenido. Este comportamiento sugiere que, a medida que se incrementa la tracción aplicada al metamaterial, menor es el grado de auxeticidad que poseen las estructuras generadas por el algoritmo. Eventualmente se puede llegar a un porcentaje de tracción en que la estructura deje de ser auxética, lo cual es bastante lógico, ya que ninguna estructura puede ensancharse infinitamente al verse sometida a tracción.

Así mismo, de la tabla 4.1 se desprende que los anchos promedio y en el centro de las estructuras en tracción van incrementando. Esto se puede apreciar gráficamente en la Figura 4.1, donde los anchos promedio y del centro de cada estructura generada incrementa según el porcentaje de tracción.

Por otro lado, si se observa en la tabla 4.1 los valores obtenidos para compresiones de 12 y 15 por ciento, éstos resultan casi idénticos, tanto en el ancho promedio como en el del centro. La Figura 4.1 refleja este comportamiento en sus curvas, que casi alcanzan una pendiente neutra. Esto podría ser un indicador que se está alcanzando el límite que el algoritmo puede generar. Este límite debe existir, ya que las estructuras no pueden ensancharse infinitamente.

Si se observa la tabla 4.2 se puede notar que el algoritmo logró generar satisfactoriamente estructuras con un Poisson Ratio específico para todos los casos. Dado que los valores buscados son siempre menores en su valor absoluto a los resultados obtenidos en la tabla 4.1, los resultados sugieren que el algoritmo podría generar estructuras que posean cualquier Poisson Ratio menos negativo que el máximo obtenido para cada deformación. Esto genera una zona de convergencia o de resultados posibles en la que, en teoría, el algoritmo puede operar de forma satisfactoria.

Por otro lado, la tabla 4.2 también muestra que la diferencia entre el Poisson Ratio obtenido y el buscado resulta ser mínima, lo cual refleja un muy buen funcionamiento del algoritmo en la búsqueda de comportamiento auxéticos específicos, al menos para los casos en que el metamaterial es sometido a tracción.

5.1.1. Estructuras generadas

La Figura 4.2 muestra que las estructuras generadas para los casos de máxima auxeticidad y búsqueda de un Poisson Ratio específico poseen una clara diferencia. Por un lado, en (a) se aprecia una estructura que posee una estructura de apariencia mucho más delgada y que ocupa casi todo el espacio en el centro de la celda, mientras que en (c) se observan celdas cuya estructura interna es mucho más abierta y alejada del centro de la celda. En ambos casos ((b) y (d)) dado que la deformación ocurrida en el metamaterial es aún muy pequeña, se hace difícil apreciar el ensanchamiento producido por la tracción.

Ya a partir de la Figura 4.3 es posible apreciar, tanto en (b) como en (d) de forma más clara el ensanchamiento que sufren los metamateriales generados por el algoritmo al ser sometido a tracción. Así como se observa que las estructuras en (a) y en (c) poseen claras diferencias, también existe una diferencia marcada en la deformación sufrida por ambas matrices. Mientras que (b) presenta un ensanchamiento mucho más marcado en el centro de la matriz, la estructura en (d) posee una deformación mucho más uniforme.

Las estructuras obtenidas para el tercer caso rompen con la tendencia observada en los dos casos anteriores. A diferencia de sus predecesores, la Figura 4.4 muestra dos estructuras (a) y (c) bastante similares y que no poseen diferencias marcadas. Este comportamiento puede hallar explicación en que la diferencia entre los Poisson Ratio es muy pequeña. Es muy difícil también apreciar diferencias en las matrices una vez deformadas ((b) y (d)).

En la Figura 4.5 se aprecia como las estructuras generadas en el caso N°4 poseen marcadas diferencias. Por un lado, la estructura en (a) sigue la tendencia de ser casi idéntica a los casos anteriores, mientras que (c) posee una estructura completamente distinta. Esta diferencia puede ser explicada por la gran diferencia que existe entre el Poisson Ratio obtenido en la primera, versus el buscado en la segunda. De esta forma, se puede notar un marcado ensanchamiento en el centro de la matriz en (b), mientras que en (d) se observa un comportamiento más uniforme.

Por último, en la Figura 4.6 se observa una estructura en (a) que es ligeramente distinta, de apariencia más delgada y cerrada que la observable en (c). Sin embargo, al ser sometidas a tracción ambas poseen un comportamiento muy similar, con un ensanchamiento bastante uniforme y no tan marcado en el centro.

Es pertinente destacar que del caso N°1 al caso N°4, las estructuras más auxéticas generadas por el algoritmo son casi idénticas, siendo el caso N°5 el único que muestra una estructura con diferencias claramente visibles. Este comportamiento sugiere que, para pequeños porcentajes de tracción, la estructura más auxética es la misma y no varía hasta alcanzar porcentajes de deformación más grandes.

El genotipo mediante el cual se generaron las estructuras también puede ser responsable de la poca variedad en las estructuras obtenidas. Dicho genotipo puede ser rígido y solo permitir que algunos tipos de estructuras auxéticas puedan ser generadas. Las estructuras que maximizan la auxeticidad son muy similares entre sí, incluso con otras estructuras que buscan un Poisson Ratio específico.

5.1.2. Curvas de aprendizaje

Al estudiar las curvas de aprendizaje para los casos de máxima auxeticidad se pueden apreciar comportamientos interesantes. En primer lugar, de forma general, todos los casos poseen curvas de Max. Fitness y Avg. Fitness que convergen hasta una meseta, con valores es muy similares en ambos casos. Esto indica que el proceso de aprendizaje que el proceso evolutivo se completó hasta alcanzar el óptimo en todos los casos.

Un fenómeno interesante de notar es cómo estas curvas de aprendizaje, desde el caso N°1 hasta el caso N°3 requieren cada vez más generaciones para converger al óptimo, pero del caso N°3 al N°5 cada vez se requieren menos. Una posible explicación para este comportamiento tiene que ver con el número de soluciones posibles a explorar. Un número elevado de generaciones indica la existencia de múltiples configuraciones candidatas para alcanzar el óptimo, mientras que una convergencia más rápida indica que los caminos para encontrar dicha solución son más acotados.

Otro comportamiento que llama la atención en estas curvas es cómo el fitness inicial, en la generación 0, es cada vez más cercano al fitness óptimo. Esto se puede apreciar muy claramente en la Figura 4.11, donde existe muy poca diferencia entre el fitness inicial y el fitness óptimo. Dicha curva refuerza la idea de que, si se sigue aumentando el porcentaje de tracción, para el algoritmo será cada vez más difícil generar estructuras auxéticas.

Por otro lado, las curvas de aprendizaje para los casos en que se busca obtener un comportamiento específico poseen todas, un comportamiento similar. Salvo la Figura 4.14, todas las curvas convergen rápidamente al resultado mucho antes del mínimo de 20 generaciones que fue fijado en un inicio. La Figura 4.14 muestra que el valor óptimo fue alcanzado cerca de la generación N°20, alcanzándose justo el umbral del fitness impuesto en un inicio para detener el algoritmo.

5.2. Compresión

A partir de la tabla 4.3 puede apreciar cómo, al igual que las simulaciones de tracción, los grados máximos de auxeticidad obtenidos son mucho más elevados para deformaciones bajas, mientras que, a mayor deformación, menor es el Poisson Ratio obtenido. Este comportamiento es muy acentuado, particularmente al pasar del caso N°7 al N°8, donde el valor absoluto del Poisson Ratio disminuye casi en una unidad completa. Este comportamiento es esperable, dado que una estructura no se puede estrechar indefinidamente, dado que tarde o temprano los elementos de ésta interfieren unos con otros.

Por otra parte, al observar la Figura 4.17 destaca un comportamiento bastante peculiar. Si bien el ancho promedio de las estructuras es estrictamente decreciente respecto al porcentaje de compresión, este comportamiento no ocurre con la medida del ancho del centro. Se puede apreciar un crecimiento de este valor para las estructuras generadas para una compresión del 12%, llegando a sobrepasar incluso el valor del ancho promedio para la misma estructura.

Este comportamiento es contraintuitivo, ya que se esperaría que una reducción en el ancho promedio de una estructura se refleje a su vez en una disminución del ancho en el centro. Esto indica que otras zonas de la estructura sufren de un angostamiento mucho más pronunciado.

Al igual que los casos de tracción, la tabla 4.4 muestra que el algoritmo logró generar satisfactoriamente estructuras con un Poisson Ratio específico para todos los casos. Los valores buscados son siempre menores en su valor absoluto a los resultados obtenidos en la tabla 4.3 y la diferencia entre los Poisson Ratio objetivo y obtenidos son mínimas y despreciables.

5.2.1. Estructuras generadas

La Figura 4.18 muestra estructuras bastante similares para los casos de máxima auxeticidad (a) y búsqueda de un Poisson Ratio (c) determinado. Este comportamiento puede hallar explicación en la cercanía que existe entre ambos Poisson Ratio, lo que produce que las diferencias en las estructuras sean mínimas. Por otro lado, a pesar de la baja compresión aplicada, se puede notar a simple vista el angostamiento de la estructura tanto en (b) como en (d), aunque dicha deformación es más evidente en el primer caso.

La Figura 4.18 muestra estructuras bastante similares para los casos de máxima auxeticidad (a) y búsqueda de un Poisson Ratio (c) determinado. Este comportamiento puede hallar explicación en la cercanía que existe entre ambos Poisson Ratio, lo que produce que las diferencias en las estructuras sean mínimas. Por otro lado, a pesar de la baja compresión aplicada, se puede notar a simple vista el angostamiento de la estructura tanto en (b) como en (d), aunque dicha deformación es más evidente en el primer caso.

La Figura 4.19, por otro lado, muestra estructuras que difieren mucho entre sí. Existe una diferencia notoria entre (a) y (c). La primera muestra celdas con patrones anchos y largos, mientras que la segunda posee un patrón mucho más angosto y corto. Al igual que en el caso anterior, en (c) y en (d) se aprecia claramente como la estructura se angosta al ser comprimida, lo cual es particularmente marcado a la altura del centro de cada celda. Se puede notar en (d) que existen pequeñas interferencias entre los elementos de la estructura en el centro de cada celda, lo que indica que esa estructura no posee mucho más margen para seguir angostándose al ser comprimida.

En la Figura 4.20 se puede observar, de manera mucho más marcada, una mayor interferencia entre elementos de la misma estructura. En (b) la estructura, al ser comprimida, entra en contacto con si misma a la altura del centro de cada celda. La forma de este contacto varía según la ubicación de la celda. Por un lado, las celdas ubicadas en las esquinas presentan un contacto lateral y no simétrico, mientras que el resto de las celdas de la estructura muestran un contacto mucho más simétrico. En cambio, la estructura mostrada en (c) está lejos de mostrar este comportamiento en (d), dejando mucho más espacio en el centro de cada celda para que su estructura converja.

La Figura 4.21 continúa con la tendencia de mostrar interferencias en la estructura al ser comprimida, aunque a diferencia de otros casos, esta interferencia no ocurre en el centro de las celdas. En (b) se muestra como esta interferencia ocurre en las celdas ubicadas en las esquinas

de la matriz, en la zona inmediatamente contigua a dichas esquinas. Destaca también que el centro de la estructura no es la parte que más se angosta al ser comprimida, sino que son las mismas celdas ubicadas en las esquinas. Este fenómeno ya había sido descrito por la tabla 4.4.

Siguiendo con el análisis de la misma figura, llama también la atención la notoria diferencia que existe entre las estructuras en (a) y (c). En particular, esta última presenta una estructura que no se asemeja a ninguna generada en casos anteriores. A simple vista, esta estructura le permite al metamaterial ser sometido a mayores porcentajes de compresión sin presentar grandes interferencias.

De forma general, en las estructuras generadas para casos de compresión destaca una mayor diversidad que en las generadas para casos de tracción. Esto es especialmente patente en los casos N°8 y N°9. Al parecer, al someter el algoritmo a mayores compresiones éste es capaz de nuevas estructuras que se adaptan a dicho modelo, de tal forma que la estructura pueda seguir angostándose sin interferencias. Es pertinente señalar que este comportamiento va de la mano con que, una vez alcanzadas compresiones mayores al 9%, el ancho final del metamaterial, tanto en promedio como en el centro, puede no disminuir de forma significativa.

5.2.2. Curvas de aprendizaje

Al igual que para los casos de tracción, las curvas de aprendizaje muestran que el resultado óptimo fue efectivamente alcanzado por el proceso evolutivo en todos los casos de estudio. En la primera etapa, en que se busca maximizar la auxeticidad, las curvas muestran convergencia entre las curvas de Max. Fitness y Avrg. Fitness hacia una meseta en las últimas generaciones del GA.

Llama la atención que tanto la Figura 4.22 como la Figura 4.23 muestran que el algoritmo requiere un total cercano a las 80 generaciones para poder alcanzar el óptimo. Este valor es muy superior a arrojado por cualquier otra curva, tanto en tracción como en compresión. Este elevado número puede indicar la existencia de múltiples candidatos posibles para resolver el problema. Para bajos porcentajes de compresión, es mucho menos probable que los elementos de una estructura interfieran entre sí, por lo que la cantidad de estructuras que se pueden generar es muy elevada. Esta hipótesis se ve reforzada por lo que muestran las Figuras 4.24 y 4.25, donde el número de generaciones requeridas para alcanzar el óptimo disminuye drásticamente. Al existir mayor compresión, muchas posibles estructuras presentan interferencias, por lo que la cantidad de candidatos se reduce de gran manera.

Finalmente, los casos en que se busca un Poisson Ratio específico presentan curvas que convergen rápidamente a 0, incluso antes del mínimo impuesto de 20 generaciones.

5.3. Doble objetivo

La tabla 4.5 muestra que, si bien el algoritmo no pudo generar una estructura que cumpliera a cabalidad con ambos objetivos al mismo tiempo, si pudo generar una estructura que posee un comportamiento muy cercano a lo deseado. Así mismo, al arrojar más de una solución, se puede optar por elegir a qué objetivo se le quiere dar más prioridad a la hora de escoger una estructura dentro de un pareto de posibilidades.

5.3.1. Estructuras generadas

Las estructuras que se pueden observar en la figura 4.30 para este caso en particular son tan similares entre sí, que a simple vista es muy difícil distinguir alguna diferencia. Este tipo de estructura, a su vez, es muy similar a las estructuras generadas en los casos de tracción en que se maximiza la auxeticidad (Ver figuras 4.3 (a) y 4.19 (b)). Este comportamiento puede ser explicado debido a que las deformaciones aplicadas son las mismas en los casos mencionados. Sin embargo, a lo largo de los resultados se puede dilucidar una tendencia clara que posee el algoritmo de generar estructuras muy parecidas entre sí. Estos resultados refuerzan la idea de que la variedad de soluciones podría estar condicionada por el genotipo utilizado.

5.3.2. Curvas de Aprendizaje

La figura 4.31 da muestras de un proceso evolutivo que funciona de forma satisfactoria. A medida que avanzan las generaciones, la curva de soluciones óptimas se acerca cada vez más al origen, el cual representa la solución óptima del problema. Este comportamiento es el esperado por un GA. Si bien solo se llegó hasta la generación N°40, el proceso iterativo puede continuar hasta que la curva de soluciones óptimas deje de acercarse al origen. Esta curva de soluciones, a su vez, entrega el total de soluciones que pueden ser elegidas para abordar el problema, de acuerdo con qué objetivo se requiera priorizar por sobre el otro.

Capítulo 6

Conclusión

El presente trabajo logra el objetivo planteado en un principio de desarrollar un método iterativo que, mediante un proceso del diseño generativo, genere estructuras que poseen un comportamiento auxético determinado. El método es muy eficaz a la hora de recibir una deformación como parámetro de entrada (ya sea de tracción como de compresión) y generar una estructura cuadrada que puede maximizar el grado de auxeticidad ante dicho estímulo. Al mismo tiempo, también posee el potencial de generar estructuras que, en vez de maximizar el comportamiento auxético, genere estructuras que apunten a un Poisson Ratio determinado. Esto último es posible siempre y cuando dicho valor sea menos negativo que el resultado alcanzado al maximizar la auxeticidad.

El método desarrollado también posee el potencial de atacar múltiples objetivos al mismo tiempo, siendo ésta una de sus principales fortalezas. Por un lado, permite hacer una exploración de las posibilidades que brinda el genotipo utilizado para generar una familia de soluciones candidatas a cumplir dichos objetivos. Si bien es difícil que una solución cumpla a cabalidad con más de un objetivo a la vez, el método permite elegir entre distintas soluciones que tranzas entre un objetivo y otro según se desee priorizar.

El genotipo desarrollado para llevar a cabo el método permite alcanzar estructuras óptimas con comportamiento auxético para un amplio abanico de casos de estudio. Sin embargo, este genotipo posee grandes limitantes. Solo se pueden generar estructuras cuadradas, de patrones repetitivos y simétricos. Así mismo, el genotipo muchas veces genera soluciones que son extremadamente parecidas entre sí, siendo difícilmente distinguibles sus diferencias a simple vista. El abanico de opciones que el genotipo ofrece representa la principal limitante del método a la hora de generar estructuras auxéticas, ya que dicho abanico podría ser muy rígido dentro de sus posibilidades.

El proceso evolutivo posee un comportamiento óptimo en todos los casos estudiados. Las curvas de aprendizaje obtenidas reflejan que el algoritmo tiene la capacidad de converger a soluciones para muchos casos distintos, pudiéndose rastrear sin mayores inconvenientes su evolución a lo largo de las iteraciones. En esta misma línea, el método mediante el cual se evalúa a los individuos resulta ser muy eficiente. Permite una evaluación rápida y eficiente del comportamiento auxético de los individuos, permitiendo al algoritmo converger hacia una solución en tiempos moderados y en un número prudente de generaciones.

Finalmente, se concluye que, a pesar de sus limitaciones, el método desarrollado constituye una buena herramienta para generar estructuras cuadradas y auxéticas en 2D que requieran simetría en su estructura. Este método posee gran eficacia tanto para maximizar el comportamiento auxético, como para resolver problemas que busquen uno o varios comportamientos específicos a la vez.

Trabajo Propuesto

Con el fin de seguir desarrollando el método propuesto en esta memoria, se proponen los siguientes aspectos para profundizar en un futuro trabajo:

- Generar genotipos que construyan matrices con configuraciones distintas a las configuraciones cuadradas. Una buena alternativa puede ser el desarrollo de genomas para matrices triangulares o hexagonales.
- Explorar con genotipos y métodos de evaluación de auxeticidad en estructuras 3D. Sería interesante explorar el potencial que posee el método desarrollado para generar estructuras auxéticas en 3D.
- Fabricar algunas de las estructuras generadas en los casos de estudio, con el objetivo de estudiar su comportamiento auxético y corroborar empíricamente que dichas estructuras se comportan como lo muestran las simulaciones realizadas en este trabajo.
- Explorar con estructuras de celda unitaria asimétricas y estudiar cómo estas estructuras afectan el comportamiento auxético de las estructuras generadas.
- Eventualmente, evaluar nuevos parámetros de evolución para el GA, de tal forma de estudiar su efecto en la convergencia del método hacia soluciones óptimas.

Bibliografía

- [1] Chunlin Ji Bin Liu. Automated metamaterial design with computer model emulation and bayesian optimization. *Applied Mechanics and Materials*, 2014. doi: 10.4028/www.scientific.net/AMM.575.201.
- [2] Y. Liebold-Ribeiro C. Komer. A systematic approach to identify cellular auxetic material. *Smart Materials and Structures*, 24(025013), 2014. doi: 10.1088/0964-1726/24/2/025013.
- [3] Monica Carfagni Francesco Buonamici. Generative design; an exploratory study. *Computer-Aided Design Applications*, 18(1):144–155, 2020. doi: 10.14733/cadaps.2021.144-155.
- [4] Libo Gao James Utama Surjadi. Mechanical metamaterials and their engineering applications. *Advanced Engineering materials*, 21(3), 2019. doi: <https://onlinelibrary.wiley.com/doi/10.1002/adem.201800864>.
- [5] Sivam Krish. A practical generative design method. *Computer-Aided design*, 43:88–100, 2011. doi: 10.1016/j.cad.2010.09.009.
- [6] Raj Das Krishna Kumar. Three decades of auxetic research - materials with negative poisson’s ratio: A review. *Advanced Engineering Materials*, 18(11):1847–1870, 2016. doi: 10.1002/adem.201600053.
- [7] Sang-Soo Ling. A novel method for the accurate evaluation of poisson’s ratio of soft polymer materials. *The scientific world journal*, 2013. doi: 10.1155/2013/930798.
- [8] Jevin West Lovenoor Aulck, Dev Nambi. Using machine learning and genetic algorithms to optimize scholarship allocation for student yield. *Conference on Knowledge Discovery and Data Mining*, 2019. doi: <https://doi.org/10.1145/1122445.1122456>.
- [9] S. Janbaz M. J. Mirzaali. Shape-matching soft mechanical metamaterials. *Scientific Reports*, 8(965), 2018. doi: s41598-018-19381-3.
- [10] Collin Richards Reeves. Genetic algorithms. *Handbook of Metaheuristics. International Series in Operations Research I& Management Science*, 146:109–139, 2010. doi: https://doi.org/10.1007/978-1-4419-1665-5_54.
- [11] Muhammad Junaid Awan Shahroz Khan. A generative design technique for exploring shape variations. *Advanced Engineering Informatics*, 38:712–724, 2018. doi: 10.1016/j.aei.2018.10.005.
- [12] Wenfeng Lu Yafeng Han. Evolutionary design of non-uniform cellular structures with optimized poisson’s ratio distribution. *Materials and design*, 141:384–394, 2018.
- [13] Amir Zadpoor. Mechanical metamaterials. *Materials Horizons*, 3(5):365–462, 2016.