



**UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS**

UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS
INSTITUTO DE INVESTIGACIÓN EN CIENCIAS BÁSICAS Y APLICADAS
CENTRO DE INVESTIGACIÓN EN CIENCIAS

**Evolución de señalización y altruismo en agentes
artificiales**

T E S I S

QUE PARA OBTENER EL GRADO DE
DOCTOR EN CIENCIAS

PRESENTA

José Manuel Pardo Cruz

DIRECTOR DE TESIS
Dr. Bruno Lara Guzmán

CUERNAVACA, MORELOS

23 de febrero de 2024

Agradecimientos

A mi asesor de tesis y amigo, el doctor Bruno Lara, por brindarme la oportunidad de formar parte de su laboratorio, un espacio donde se fomenta la libertad intelectual, el crecimiento, el aprendizaje y el intercambio de ideas. Por sus valiosas orientaciones, sugerencias y comentarios que enriquecieron esta tesis. Por sus interminables discusiones y charlas que me motivaron a seguir adelante.

A mis compañeros de laboratorio, en especial a la Doctora Alejandra Ciria, por su apoyo incondicional, tanto emocional como intelectual, que fue fundamental para el desarrollo de esta investigación.

Dedicatoria

A mi mujer y mis hijas, por ser lo mejor que me ha pasado y formar parte de esta etapa crucial y hermosa de mi vida.

RESUMEN

Evolución de señalización y altruismo en agentes artificiales

José Manuel Pardo Cruz

La emergencia de conductas altruistas en poblaciones de robots autónomos, especialmente en tareas de señalización y forrajeo, ha demostrado ser un problema difícil de modelar a través del uso de algoritmos evolutivos, esto a pesar del hecho de que las conductas de señalización y altruismo están presentes a lo largo de todo el árbol de la vida. Especialmente, porque las conductas de señalización parecen haber evolucionado múltiples veces en el árbol de la vida, siempre que ha existido un canal para emitir una señal y recibirla. En este trabajo, este problema es estudiado usando algoritmos evolutivos, y modelando fenómenos como la selección por parentesco, la discriminación por parentesco y el gen de la barba verde. Al mismo tiempo se hace uso de mapas auto organizados para observar el comportamiento de las poblaciones en el espacio de soluciones, durante el proceso evolutivo. Creemos que esta aproximación puede servir para dilucidar el poder predictivo de la regla de Hamilton, la importancia de la selección por parentesco en la emergencia de conductas altruistas. Resolver este problema, no solo mostraría que la robótica evolutiva es capaz de modelar el surgimiento del altruismo de una forma biológicamente plausible, también nos daría indicios de como modelar el surgimiento de otras habilidades cognitivas presentes en los organismos biológicos.

Índice general

CAPÍTULO

1. Introducción	1
1.1. Objetivos y preguntas de investigación	2
1.2. Crítica a la robótica evolutiva	3
1.3. Problemas abiertos	5
1.3.1. Problema de la escalabilidad	5
1.3.2. Problema de la evolucionabilidad	6
1.3.3. ¿Cuál es el inconveniente con las soluciones dadas a estos problemas?	7
1.3.4. Ventajas de la robótica evolutiva	9
2. Marco teórico	11
2.1. Definiciones operacionales	11
2.2. Redes neuronales artificiales	14
2.2.1. Transmisión de información en redes <i>feed-</i> <i>forward</i>	16
2.2.2. Aprendizaje supervisado y no supervisado .	17
2.2.3. SOM	18
2.3. Robótica cognitiva y Robótica evolutiva	20
2.4. Algoritmos genéticos	22
2.4.1. Representación de los individuos	23
2.4.2. Métodos de selección	24
2.5. Estado del arte	31
2.5.1. ¿Por qué centrarnos en la señalización de comida?	33
2.5.2. Propuesta experimental	34
3. Metodología	37
3.1. Simulador y robots	37
3.1.1. Simulador	37
3.1.2. Robots	38
3.2. Mapas Auto Organizados (SOM)	38
3.2.1. Entrenamiento del SOM	40

4. Experimentos y resultados	43
4.1. Experimento 1: Evolución de altruismo informando a los robots de su parentesco	43
4.1.1. Entorno y robots	43
4.1.2. Variables durante el proceso de evolución	46
4.1.3. ¿Es la emisión de luz azul una señal altruista?	49
4.1.4. ¿Es la emisión de luz una señal confiable de comida?	49
4.1.5. Pruebas para determinar si la emisión de luz es una señal confiable de comida	50
4.1.6. Pruebas para determinar el nivel de altruismo	54
4.1.7. Resultados estadísticos de la prueba de al- truismo experimento 1	55
4.1.8. Graficar las poblaciones utilizando SOMs	59
4.2. Experimento 1.1: Evolución con parentesco invertido	67
4.2.1. Entorno y robots	67
4.2.2. Red neuronal	67
4.2.3. Escenario	68
4.2.4. Variables durante el proceso de evolución	68
4.2.5. Prueba de altruismo con parentesco invertido	70
4.2.6. Resultados de la prueba de altruismo	70
4.3. Experimento 2 y 2.1, percibiendo solo el color del otro robot, red con una capa oculta	73
4.3.1. Experimento de selección por similitud fe- notípica	73
4.3.2. Entorno y robots del experimento 2	73
4.3.3. Variables durante el proceso de evolución experimento 2	77
4.3.4. Pruebas para determinar si la emisión de luz es una señal confiable de comida en el experimento 2	79
4.3.5. Pruebas para determinar el nivel de altruismo	81
4.3.6. Resultados de la condición de abundancia (Experimento 2.1)	83
4.3.7. Resultados de la condición comida variable	85
4.3.8. Graficar las poblaciones finales del experi- mento 2	95
4.4. Experimento 3, percibiendo el color de ambos robots, red con una capa oculta	97
4.4.1. Entorno y robots experimento 3	98

4.4.2.	Variables durante el proceso de evolución del experimento 3	100
4.4.3.	Pruebas para determinar si la emisión de luz es una señal confiable de comida en el experimento 3	101
4.4.4.	Pruebas para determinar el nivel de altruismo en el experimento 3	103
4.5.	Experimento 4, percibiendo el color del otro robot, red con dos capas ocultas	107
4.5.1.	Entorno y robots experimento 4	108
4.5.2.	Variables durante el proceso de evolución	110
4.5.3.	Pruebas de altruismo experimento 4	113
4.6.	Experimento 5, percibiendo el color de ambos robots, red con dos capas ocultas	113
4.6.1.	Entorno y robots experimento 4	114
4.6.2.	Variables durante el proceso de evolución	115
4.6.3.	Pruebas para determinar si la emisión de luz es una señal confiable de comida	116
4.6.4.	Generaciones a medir	120
4.6.5.	Búsqueda de individuos con comportamiento cercano a la regla de Hamilton en el experimento 3	143
4.6.6.	Resultados para las generaciones con alta agrupación (baja entropía)	147
4.6.7.	Resultados para las generaciones con baja agrupación (alta entropía)	154
4.6.8.	Resultados para las generaciones con baja emisión	160
4.6.9.	Resultados para las generaciones con alta emisión	166

Índice de figuras

2.1.	Esquema algoritmo genético	23
2.2.	Proceso de cruza	29
2.3.	Proceso de cruza 2	30
4.1.	Expresión fenotípica AG	44
4.2.	Red neuronal experimento 1	45
4.3.	entorno	46
4.4.	Diferencias condición encendida y a ciegas experimento 1 . .	52
4.5.	Red con falso parentesco del experimento 1	55
4.6.	Resultados del experimento 1	59
4.7.	Poblaciones graficadas en el SOM para la condición Comida	
	1.0	61
4.8.	Poblaciones graficadas en el SOM para la condición Comida	
	1.2	61
4.9.	Poblaciones graficadas en el SOM para la condición comida	
	1.4	62
4.10.	Poblaciones graficadas en el SOM para la condición Comida	
	1.6	62
4.11.	Poblaciones graficadas en el SOM para la condición Comida	
	1.8	63
4.12.	Poblaciones graficadas en el SOM para la condición comida	
	2.0	63
4.13.	Posición de cada uno de los individuos para una corrida del algoritmo genético en diferentes etapas del proceso (Condi- ción comida 2.0). El espacio de solución está representado por un SOM cúbico, cada punto representa la neurona ga- nadora correspondiente al individuo que se presentó como entrada al SOM, la intensidad del color azul de cada punto representa el nivel de emisión de luz azul dentro de la región de interés durante el proceso evolutivo , y, normalizado entre 0 y 1.	64

4.14.	Emisión de luz dentro de la región de interés para la última generación (50 individuos) de una corrida del algoritmo evolutivo, para la condición comida 2.0, bajo cada una de las condiciones de parentesco, el color de los círculos representa la emisión de luz azul de cada uno de los individuos dentro de la región de interés para cada una de estas condiciones experimentales.	65
4.15.	Promedio de emisión experimento 1.1	72
4.16.	Red neuronal experimento 2	74
4.17.	Ambiente de simulación	75
4.18.	ejemplo SOM	77
4.19.	Diferencias luz encendida y a ciegas experimento 2	81
4.20.	Promedio de emisión experimento 2	84
4.21.	Promedio de emisión experimento 2 comida variable	86
4.22.	Promedio de emisión, en el experimento 2, comida variable	90
4.24.	Espacio de solución experimento 2	96
4.25.	Espacio de solución, experimento 2, comida variable	97
4.26.	Red neuronal experimento 3	99
4.27.	Diferencias entre luz encendida y luz apagada experimento 3	103
4.28.	Promedio de emisión experimento 3	105
4.29.	espacio de solución experimento 3	106
4.30.	Espacio de solución del experimento 3, comida variable	107
4.32.	Diferencias luz encendida y a ciegas experimento 4	111
4.33.	Diferencias luz encendida y generación 1 4	112
4.34.	Diferencias luz encendida, luz encendida generacion 1 y a ciegas experimento 4	114
4.36.	Diferencias luz encendida y a ciegas experimento 5	118
4.37.	Entropía de Shannon de la corrida 1 del algoritmo evolutivo, en el eje de las y y la cantidad de entropía promedio de cada generación	121
4.38.	Entropía de Shannon de la corrida 2 del algoritmo evolutivo, en el eje de las y y la cantidad de entropía promedio de cada generación	122
4.39.	Entropía de Shannon de la corrida 3 del algoritmo evolutivo, en el eje de las x el número de generación y en el eje de las y la cantidad de entropía de cada generación	123
4.40.	Entropía de Shannon de la corrida 4 del algoritmo evolutivo, en el eje de las y y la cantidad de entropía promedio de cada generación	124

4.46.	Gráfica de violines para el 20 % de individuos más emisor de las generaciones menos agrupadas, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana . . .	132
4.49.	Gráfica de violines para el 20 % de individuos más emisor de las generaciones más agrupadas, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana	135
4.52.	Gráfica de violines para el 20 % de individuos más emisor de las generaciones más emisoras, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana	138
4.55.	Gráfica de violines para el 20 % de individuos más emisores de las generaciones con menor emisión de luz azul en la región de interés. El punto blanco representa el promedio de emisión y el verde la mediana.	141
4.60.	Subfiguras de las gráficas de violines para el 10 % de individuos que mejor se ajustan a la emisión idealizada dentro de las poblaciones más agrupadas	152
4.61.	Resultados del experimento 5 pruebas para las generaciones de baja entropía	153
4.63.	Gráficas de violines para el 10 % de individuos que mejor se ajustan a la emisión idealizada de las generaciones menos agrupadas, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo. El punto blanco representa el promedio de emisión y el verde la mediana.	159
4.64.	Resultados del experimento 5 pruebas para las generaciones de alta entropía	159
4.65.	Gráfica de violines para el 10 % de individuos que mejor se ajustan a la emisión idealizada de las generaciones más emisoras, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana.	164
4.66.	Resultados del experimento 5 pruebas para las generaciones de baja emisión	165

4.68.	Gráfica de violines para el 20 % de individuos más emisor de las generaciones más emisoras, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana.	170
4.69.	Resultados del experimento 5 pruebas para las generaciones de alta emisión	171

Índice de cuadros

2.1. Artículos relacionados	32
4.1. Condiciones de evolución experimento 1	46
4.2. Variación costo beneficio	47
4.3. Resultados de regla de Hamilton experimento 1	50
4.4. Pruebas de altruismo experimento 1	53
4.5. Resultados del grupo comida 2.0	56
4.6. Resultados del grupo Comida 1.8	56
4.7. Resultados del grupo comida 1.6	57
4.8. Resultados del grupo comida 1.4	57
4.9. Promedios de emisión para cada condición experimento 1	59
4.10. Valores regla de Hamilton	60
4.11. Condiciones de evolución parentesco invertido	69
4.12. En este cuadro se puede ver como cambia el resultado de aplicar en cada una de las 6 condiciones de prueba, nótese que en este caso normalización del parentesco percibido está invertido, pero para el cálculo de la regla de Hamilton se usa su valor de forma normal	70
4.13. Resultados prueba altruismo experimento 1	72
4.14. Condiciones de evolución para cada condición de evolución modelando barba verde.	78
4.15. Condiciones de prueba para determinar nivel de altruismo en la condición de abundancia	82
4.16. Condiciones de prueba para determinar nivel de altruismo experimento 2 en la condición comida variable	82
4.17. Resultados del grupo comida 2.0	85
4.18. Resultados del grupo comida 2.0	91
4.19. Resultados del grupo comida 1.8	92
4.20. Resultados del grupo comida 1.6	92
4.21. Resultados del grupo comida 1.4	93
4.22. Resultados del grupo comida 1.2	93
4.23. Resultados del grupo comida 1	94
4.24. Condiciones de evolución para cada condición de evolución en el experimento 3.	100
4.25. Pruebas altruismo experimento 3	104

4.26. Condiciones de evolución para el experimento 4.	110
4.27. Condiciones de evolución en el experimento 5.	116
4.28. Condiciones de prueba para determinar nivel de altruismo . .	119
4.29. En la tabla se muestran las 9 generaciones de cada una de las cuatro condiciones; alta agrupación, baja agrupación, alta emisión, baja emisión elegidas para realizar las pruebas . . .	130
4.38. Resultados del grupo comida 2.0	148
4.39. Resultados del grupo comida 1.8	148
4.40. Resultados del grupo comida 1.6	149
4.41. Resultados del grupo comida 1.4	150
4.42. Resultados del grupo comida 1.2	150
4.43. Resultados del grupo comida 1.0	151
4.44. Resultados del grupo comida 2	155
4.45. Resultados del grupo comida 1.8	155
4.46. Resultados del grupo comida 1.6	156
4.47. Resultados del grupo comida 1.4	157
4.48. Resultados del grupo comida 1.2	157
4.49. Resultados del grupo comida 1.0	158
4.50. Resultados del grupo comida 2	160
4.51. Resultados del grupo comida 1.8	161
4.52. Resultados del grupo comida 1.6	162
4.53. Resultados del grupo comida 1.4	162
4.54. Resultados del grupo comida 1.2	163
4.55. Resultados del grupo comida 1.0	163
4.56. Resultados del grupo comida 2	167
4.57. Resultados del grupo comida 1.8	168
4.58. Resultados del grupo comida 1.6	168
4.59. Resultados del grupo comida 1.4	169
4.60. Resultados del grupo comida 1.2	169
4.61. Resultados del grupo comida 1.0	170

CAPÍTULO 1

Introducción

El altruismo se ha definido como un comportamiento que reduce la capacidad reproductiva esperada del individuo o individuos que realizan dicha acción (Axelrod y Hamilton, 1981; Bourke, 2021; Floreano, Mitri, Perez-Uribe, y Keller, 2008; Kay, Keller, y Lehmann, 2020). A primera vista, esto parece entrar en conflicto con el concepto darwiniano de selección natural, entendido como “la supervivencia del más apto” Kay y cols. (2020). Sin embargo, esta aparente paradoja desaparece cuando consideramos los genes de los individuos como la unidad de selección.

En esta tesis, nos centramos especialmente en este fenómeno, que ha resultado particularmente difícil de abordar para la robótica evolutiva: la aparición del comportamiento altruista, sobre todo mediante el uso de la señalización.

Para poder introducir el tema, hablamos de robótica evolutiva, como el área de la robótica que hace uso de algoritmos evolutivos, esto se profundizara en la sección 2.4. Por el momento, baste describirlos como la creación de una población aleatoria de individuos cuya tarea es resolver un problema. Algunos de estos individuos se seleccionan para entonces reproducirse y dar lugar a una nueva población. Con el paso de las generaciones, se espera que los individuos se acerquen a poder solucionar el problema.

Hasta ahora, evolucionar conductas altruistas en robots autónomos, usando algoritmos evolutivos, poblaciones heterogéneas y selección individual, ha resultado imposible (**Cuadro 2.1**). Creemos que la razón primordial por la cual intentos previos han fracasado, es la ausencia de un correcto modelado de fenómenos que ocurren en los organismos biológicos durante el proceso evolutivo y que son necesarios para que estas conductas surjan. De particular importancia, se propone aquí:

- Selección por parentesco: la cual es el proceso evolutivo que favorece la transmisión de genes a través de la ayuda a los parientes biológicos del individuo, con los cuales comparten esos genes.
- Discriminación por parentesco: la cual es, la capacidad de los individuos para reconocer y diferenciar a sus parientes de los no parientes, y ajustar su comportamiento en consecuencia.

- El gen de la barba verde (propuesto por Dawkins (1976)): este postula que existe un gen que produce tres efectos: uno es hacer que el individuo tenga una barba verde, hacer que el individuo reconozca a otros individuos con la barba verde y por último que muestre una conducta que beneficie a esos individuos.

Intentamos para ello abordar su modelado de una forma biológicamente plausible. Un enfoque biológicamente plausible es esencial para entender el surgimiento de conductas altruistas en robots autónomos, ya que esto nos permite explorar cuáles elementos son necesarios para su aparición y cómo pueden ser implementados de manera más efectiva. Además, al modelar los fenómenos de forma biológicamente plausible, se pueden plantear analogías con su surgimiento en agentes biológicos, lo que nos permite obtener una mayor comprensión de cómo funcionan y cómo pueden ser aplicados en sistemas artificiales.

1.1. Objetivos y preguntas de investigación

El objetivo de este trabajo es investigar la posibilidad de modelar el surgimiento de conductas de altruismo, a través de señalización, en agentes artificiales, haciendo uso de los principios de la teoría de la evolución biológica. Para ello, analizaremos las condiciones mínimas necesarias que deben ser modeladas. Asimismo, evaluaremos si este modelo puede usarse para estudiar procesos cognitivos y generar conductas flexibles en agentes artificiales.

Las preguntas de investigación que nos guían en este estudio son:

- ¿Es posible lograr el surgimiento de altruismo, mediante señalización, en agentes artificiales usando los principios de la teoría de la evolución biológica?
- ¿Cuáles son las condiciones mínimas necesarias que deben ser modeladas para este propósito?
- ¿Podemos estudiar procesos cognitivos usando este tipo de modelado?
- ¿Este tipo de modelado puede ayudar a generar conductas flexibles en agentes artificiales?

Como se mencionó anteriormente, para lograr esto, se explorara el fenómeno de la selección por parentesco y la discriminación por parentesco,

así como el gen de la barba verde. Estos conceptos son relevantes para entender cómo se da el surgimiento de conductas altruistas en poblaciones de agentes artificiales y cómo la relación genética entre ellos puede influir en su comportamiento.

1.2. Crítica a la robótica evolutiva

La robótica evolutiva es una rama de la robótica que se basa en los principios de la evolución biológica para diseñar y mejorar agentes artificiales que puedan adaptarse a su entorno. Esta disciplina está relacionada con la robótica cognitiva, que estudia cómo el cuerpo y el medio ambiente influyen en el desarrollo de procesos cognitivos en los agentes. La robótica cognitiva parte de la idea de que el conocimiento y la cognición no son solo producto del cerebro, sino que emergen de la interacción entre el cuerpo del robot y su entorno. Tal como lo hace nuestra investigación, enmarcamos nuestro trabajo dentro de la cognición corporizada, la cual enfatiza la importancia del cuerpo de los agentes para el surgimiento de procesos cognitivos [Bongard \(2013\)](#).

En este trabajo, uno de los principales métodos y técnicas de la robótica evolutiva son los algoritmos genéticos, los cuales, junto con los algoritmos evolutivos y la vida artificial, son herramientas computacionales que simulan el proceso evolutivo para encontrar soluciones óptimas a problemas complejos. Estos métodos se han utilizado tanto para investigar tanto la cognición como para resolver problemas de ingeniería. Además, se discuten algunas de las limitaciones y desafíos de la robótica evolutiva como herramienta para comprender los procesos cognitivos y la evolución en general ([Doncieux, Bredeche, Mouret, y Eiben, 2015](#); [Nolfi y Floreano, 2000](#)).

Además, se discuten algunas de las limitaciones y desafíos de la robótica evolutiva como herramienta para comprender los procesos cognitivos y la evolución en general.

Aunque esta crítica es válida en sus premisas, no es tan significativa como podría parecer. La evolución es un proceso independiente del sustrato en el que ocurre ([Dawkins, 1976](#); [Dennett, 2002](#)), lo que implica que la evolución se dará siempre que se cumplan tres requisitos básicos: reproducción, variación y competencia ([Dennett, 2002](#)). Coincidimos con [Cliff, Husbands, y Harvey \(1993\)](#) en que los problemas que debe resolver un agente artificial autónomo pueden ser modelados de forma que no difieran mucho de los que enfrentan sus equivalentes biológicos.

Esto se logra mediante la representación de los "genes" en cadenas bi-

narias, que se mapean directamente a una expresión fenotípica. El ejemplo clásico es la codificación de un peso sináptico entre dos neuronas de una red neuronal artificial. De esta manera, incluso las formas más simples de modelado de los procesos evolutivos, como los algoritmos genéticos, pueden generar soluciones efectivas a problemas considerados de alta complejidad utilizando redes neuronales artificiales sencillas.

Lo anterior se muestra en los múltiples trabajos presentados por [Floreano y Keller \(2010\)](#), donde se utilizan algoritmos genéticos en su forma más “básica”, esto es: en la evolución de agentes artificiales, cada gen del individuo se mapea en un peso de conexión de la red neuronal artificial. No se modelan las interacciones entre los genes, el desarrollo ontogenético, las descargas neuronales ni se tiene en cuenta la duración de vida de los individuos.

A pesar de estas limitaciones, se han logrado evolucionar fenómenos tales como la evasión de obstáculos, la capacidad de un agente artificial para encontrar su madriguera, dinámicas de co-evolución presa/depredador, conductas de cooperación, el surgimiento de comunicación entre agentes y la capacidad de distinguir entre comida y veneno ([Floreano, Mitri, Magnenat, y Keller, 2007](#)). Esto se logra evolucionando tan solo unos pocos cientos de generaciones ([Floreano y Keller, 2010](#); [Floreano y cols., 2007](#)).

Esta idea de que modelos relativamente sencillos pueden dar cuenta de conductas complejas realizadas por agentes biológicos es defendida por [Brooks \(1991\)](#). En el marco de la cognición corporizada, propone que una vez que asumimos que “el mundo es el mejor modelo de sí mismo”, las conductas de los organismos biológicos poco complejos pueden ser modeladas de una forma mucho más sencilla de lo que se había asumido hasta ese momento. Lanza a su vez la hipótesis de que este paradigma es muy posiblemente escalable a fenómenos cognitivos presentes en organismos mucho más complejos. Todo lo anterior parece dar indicios de que, dependiendo del nivel de análisis o fenómeno evolutivo que se quiera estudiar, no es necesario o siquiera deseable en algunos casos intentar modelar todas las variables que se dan dentro de la evolución de los agentes biológicos.

El uso de la robótica evolutiva como herramienta para el estudio de la evolución y los procesos cognitivos ha llevado a intentar trabajar con modelos más completos. Estos modelos intentan incluir cada vez más las complejas interacciones que se dan en la evolución de agentes biológicos, por ejemplo:

1. evolucionar no solo la red neuronal artificial que controla a los agentes artificiales, sino co-evolucionar al mismo tiempo su morfología ([Ber-](#)

natskiy y Bongard, 2018; Cheney, Bongard, Sunspirial, y Lipson, 2016; Sims, 1994),

2. simular redes neuronales capaces de aumentar su complejidad a través del proceso evolutivo conocidas como NEAT «Neuro Evolution of Augmenting Topologies» (Stanley, Stanley, Miikkulainen, y Miikkulainen, 2002)
3. modelar las interacciones que ocurren en la co-evolución del controlador y la morfología del agente cuando se cambia el ambiente donde este evoluciona (Auerbach y Bongard, 2012)
4. uso de operadores epigenéticos en la expresión fenotípica de agentes artificiales simulados y físicos (Brawer y cols., 2017).

Por último, como señala Harvey, Paolo, Wood, Quinn, y Tuci (2005), existe una simplificación excesiva cuando se estudian procesos cognitivos o evolutivos en agentes artificiales. Sin embargo, estos resultados pueden ser utilizados como una herramienta para comprender las condiciones mínimas necesarias para que la evolución de cierto proceso cognitivo se produzca. En caso de ser posible, se pueden poner a prueba dichas conclusiones en agentes biológicos.

1.3. Problemas abiertos

Sin embargo, debemos admitir que existen algunos problemas que la robótica evolutiva aún no ha podido resolver de forma contundente. Aquí se presentan dos problemas que son particularmente apremiantes: el problema de la escalabilidad y de la evolucionabilidad.

1.3.1. Problema de la escalabilidad

El primero de ellos es la falta de escalabilidad de las habilidades cognitivas de los agentes artificiales. Varias investigaciones han señalado que la robótica evolutiva tiende a generar soluciones reactivas en lugar de soluciones cognitivas (Lehman y Miikkulainen, 2014). Un ejemplo destacado de soluciones reactivas son las redes neuronales evolucionadas para resolver problemas de evasión, que muestran un comportamiento muy similar al de los robots tipo Braitenberg. Estos son vehículos con motores diferenciales propuestos en una serie de experimentos mentales por Valentino Braitenberg, en los que se muestra que se pueden generar conductas aparentemente

complejas al cablear directamente los distintos sensores del vehículo a sus motores. Este es un modelo de un agente que se mueve de forma autónoma en función de sus entradas sensoriales. En el ejemplo propuesto, el agente cuenta con dos sensores simétricos, detectores de luz, que estimulan cada una de las ruedas del mismo lado del cuerpo. Esto produce la siguiente conducta: más luz produce un movimiento más lento, menos luz produce un movimiento más rápido. De esta manera, el vehículo parece evitar la luz y buscar la oscuridad (Braitenberg, 1986). Si se sustituyen los sensores de luz por sensores de distancia, este vehículo es capaz de evadir obstáculos. Por otro lado, una solución más cognitiva permitiría no solo reaccionar ante obstáculos de manera efectiva, sino también aprender de las experiencias y tomar decisiones más adaptativas basadas en el contexto actual y el conocimiento acumulado.

Aquí se plantea que el problema de la escalabilidad puede deberse a varias razones:

- La primera es que, como en el caso de la evasión de obstáculos, el algoritmo evolutivo converge en alguna solución óptima, que resulta ser la más sencilla. La evolución por selección natural es 'ciega', ya que no se preocupa por el tipo de solución, siempre y cuando permita una mejora en la aptitud del agente. En el problema mencionado, esta solución probablemente se parecerá a un Vehículo Braitenberg, que representa la solución mínima necesaria para resolver el problema.
- La segunda, como señala el mismo Lehman y Miikkulainen (2014), es que normalmente los mecanismos cognitivos complejos requieren de la suma de varios mecanismos. Es decir, son el resultado de diversas mutaciones que deben sumarse con el tiempo para ser útiles en la resolución de un problema. Sin embargo, esto no sucede fácilmente en el caso de los algoritmos evolutivos, ya que debido al inmenso espacio de solución que cualquier problema presenta, es difícil que estas mutaciones se presenten juntas por mera casualidad.
- Por último, hay que considerar que esto puede deberse a que quizá se desconocen aún los mecanismos, más allá de la selección natural, que deben ser modelados en agentes artificiales para permitir el surgimiento de soluciones sofisticadas o creativas.

1.3.2. Problema de la evolucionabilidad

Lo anterior se relaciona profundamente con el segundo problema que se abordará aquí, el problema de la evolucionabilidad. En la robótica evolutiva

y en la biología, no hay un consenso sobre lo que se entiende por evolucionabilidad (Lehman, Wilder, y Stanley, 2016; Pigliucci, 2008; Wilder y Stanley, 2015). Aquí, se adoptará la definición dada por Lehman y cols. (2016), que señala que en términos generales se trata de la capacidad de un algoritmo evolutivo de hacer que los miembros de una población se muevan a través del espacio de solución del problema de una forma eficaz. Este movimiento produciría soluciones o comportamientos novedosos -diferenciables entre sí- conforme van avanzando las generaciones. Como ya se mencionó, cada generación consta de un número de individuos que ha sido creado a partir de sus ancestros. Estos individuos, en un principio, están ubicados de manera aleatoria en el espacio de solución del problema.

Resolver este problema no ha sido tan fácil de lograr como se había pensado. Es común que el algoritmo encuentre una solución a la tarea, pero que esta esté lejos de ser una solución óptima, siendo solamente un mínimo local, lo que hace que la búsqueda de soluciones se centre alrededor de este mínimo local.

Uno de los factores conocidos por los cuales esto ocurre es que cuando el algoritmo encuentra un “mínimo local”, el *acervo* genético de la población converge rápidamente alrededor de dicha solución debido al proceso de selección. Tradicionalmente, se ha considerado a la mutación como la forma de ampliar el espacio de búsqueda, sin embargo, es más común que una mutación ocasione detrimento al agente que muta. Debido a que una de las características de los algoritmos evolutivos es que su espacio de soluciones posibles suele ser extremadamente grande, las soluciones que resuelven determinado problema son mucho menores en número a aquellas incapaces de resolverlo, por lo que resulta mucho más probable que un individuo que presenta una mutación drástica, presente una aptitud mucho más baja que aquellos que se han mantenido cerca de la solución ya alcanzada, provocando que los genes de este nuevo individuo se elimine del *acervo* genético de la población.

1.3.3. ¿Cuál es el inconveniente con las soluciones dadas a estos problemas?

Si bien hay intentos de solucionar estos problemas, aquí se plantea que algunos de ellos tienen fallas fundamentales. A menudo, los investigadores intentan forzar estos procesos de evolucionabilidad y escalabilidad utilizando mecanismos que son ajenos a la teoría evolutiva y biológicamente poco plausibles.

Un ejemplo de este tipo de soluciones se encuentra en los trabajos de

Lehman y Stanley (2008); Stanley y Miikkulainen (2004); Stanley y cols. (2002), donde se genera la especiación de la población a través de mecanismos de búsqueda de novedad. Estos mecanismos premian la aptitud de un individuo simplemente por ser una solución novedosa, lo cual no parece tener un fundamento en los procesos evolutivos conocidos ni ser biológicamente plausible.

Los mecanismos de búsqueda de novedad han demostrado un mejor desempeño en la resolución de este tipo de problemas en comparación con los enfoques basados en métodos adaptativos (Wilder y Stanley, 2015). Sin embargo, no tiene sentido forzar estos fenómenos si el objetivo es entender cómo suceden estos procesos en los agentes biológicos.

Por ello es importante volver a las preguntas que comparten la biología y la robótica evolutiva:

La robótica evolutiva y la biología comparten interés en la siguiente pregunta: ‘¿Cuáles son las características clave de la evolución natural que la hace tan exitosa en producir la extraordinaria variedad de formas de vida altamente adaptadas presentes en el planeta?’¹ (Nolfi y Floreano, 2000).

Por esta razón, en este trabajo se intenta encontrar cuáles son las características clave mencionadas por Nolfi y Floreano (2000) y modelarlas. Resulta interesante utilizar lo mejor de ambos enfoques de la robótica evolutiva mencionados anteriormente. Por un lado, se mantienen modelos mínimos como los planteados por Floreano y Keller (2010); Floreano y cols. (2007). Por otro lado, es fundamental tener en cuenta que ciertos procesos cognitivos dependen de factores distintos a la selección natural. Por lo tanto, es pertinente analizar y probar estos factores en cada caso particular y luego modelarlos para su estudio. Con el objetivo de mantener el modelado en un nivel relativamente simple, se utilizan algoritmos genéticos y redes neuronales artificiales para controlar agentes artificiales en un entorno simulado, utilizando el simulador Enki (Magenat, Waibel, y Beyeler, 2009). Existen extensos ejemplos del uso exitoso de estos métodos en el modelado de tareas (Bongard, 2013; Cliff y cols., 1993; Harvey, Husbands, Cliff, Thompson, y Jakobi, 1997).

¹“Evolutionary robotics and biology share an interest in the following question: what are the key characteristics of natural evolution that make it so successful in producing the extraordinary variety of highly adapted life forms present on the planet?”

1.3.4. Ventajas de la robótica evolutiva

Adoptar este enfoque en el estudio de la cognición presenta diversas ventajas. La primera de ellas es que nos permite poner a prueba diversas teorías o modelos que pretenden explicar cierto fenómeno o capacidad cognitiva y que por sus características sea extremadamente difícil o imposible someter a prueba en agentes biológicos. Aunque es cierto que se realizan pruebas de evolución en agentes biológicos mediante lo que se conoce como ‘evolución experimental’ (Kawecki y cols., 2012), estos presentan sus propios obstáculos, como el hecho de que pueden resultar prohibitivos en términos temporales. Incluso los experimentos realizados con organismos con un ciclo de vida relativamente corto, como las bacterias, pueden tomar años en su realización. Por ejemplo, los experimentos realizados por Lenski, Rose, Simpson, y Tadler (1991) que estudian la evolución y miden la aptitud (capacidad reproductiva de la población de *E. coli* cultivada en ambientes con pocos nutrientes disponibles) de 12 poblaciones de *E. coli* cultivadas en laboratorio, en un ciclo de reproducción de 40.000 a 50.000 generaciones, tomaron más de una década en su realización. Esto demuestra que los fenómenos que se presentan en organismos con un ciclo de vida más largo que el de las bacterias simplemente serían inviables.

La robótica evolutiva, en cambio, nos permite estudiar el proceso evolutivo en un tiempo que no se relaciona al tiempo real y que está marcado por las propias características de los equipos de cómputo, así como de las implementaciones específicas. En la evolución biológica, el proceso de selección natural y el surgimiento de nuevas características adaptativas pueden tomar mucho tiempo y requerir grandes cantidades de individuos y generaciones. En cambio, en la robótica evolutiva, es posible controlar el tiempo y el tamaño de las poblaciones, lo que permite observar y evaluar el proceso evolutivo en un plazo más corto. Esto no solo acelera el proceso de investigación, sino que también permite realizar experimentos de evolución más complejos y detallados.

Otro problema con el que nos encontramos al intentar estudiar este tipo de fenómenos es que las técnicas utilizadas tradicionalmente para estudiar la aparición de ciertas capacidades, como recurrir al registro fósil, no pueden aplicarse en estos casos. Según Vonk y Aradhye (2015), las capacidades cognitivas no pueden ser estudiadas a través del registro fósil. En su lugar, tenemos ejemplos procedentes de la robótica evolutiva, como los experimentos realizados por Floreano y cols. (2007), donde se estudia experimentalmente la emergencia de la comunicación en agentes artificiales a través del proceso evolutivo, o diversos estudios que analizan la emergencia y estructura del

lenguaje a partir de la robótica evolutiva (Steels, 2003).

La robótica evolutiva además permite no solo observar el proceso evolutivo, sino intervenir en formas que sería imposible hacerlo en agentes biológicos, por ejemplo la robótica evolutiva permite:

- Volver a cualquier punto de la evolución de cierto agente artificial.
- modificar las condiciones de su ambiente en cualquier punto dentro del proceso evolutivo.
- Cambiar las presiones de selección, de igual manera, en cualquier punto del proceso evolutivo.
- Eliminar de forma artificial cierto genoma de la población para estimular el surgimiento de nuevas soluciones a un mismo problema.
- Forzar la especiación dentro del *acervo* genético que estamos evolucionando (Stanley y Miikkulainen, 2004), para fomentar el surgimiento de soluciones más novedosas, complejas y eficaces a un problema.
- Analizar cuáles son las condiciones mínimas necesarias para que la especiación suceda de forma no forzada en agentes artificiales.

CAPÍTULO 2

Marco teórico

2.1. Definiciones operacionales

Antes de explicar por qué se decidió modelar la señalización y el altruismo, parece importante aclarar las definiciones que se adoptaron de dichos términos y algunos otros relacionados con las tareas a modelar, estos son señalización, señal confiable, señal engañosa, efecto de la barba verde y altruismo.

Señalización En el caso de la señalización se parte de la definición de señal dada por [Otte \(1974\)](#) “Las señales son definidas como conductas, psicológicas o características morfológicas desarrolladas o mantenidas por la selección natural porque transmiten información a otros organismos”¹. Esta definición tiene varias ventajas:

1. Es lo suficientemente abstracta para no estar atada a ningún canal de transmisión específico ([Searcy y Nowicki, 2005](#)).
2. Excluye transmisiones de información que cierto organismo puede producir debido a sus características propias, sin que estas hayan evolucionado específicamente para ello, por ejemplo, la información que un humano transmite mediante su sudor a un mosquito ([Searcy y Nowicki, 2005](#)).
3. Es compatible con ambas teorías de cómo pudo surgir la señalización; por ritualización o coerción, en ambos casos, que la señal utilizada ha sido seleccionada porque coincidía en tiempo, lugar y de forma beneficiosa para el emisor, con aquello que señala ([Scott-Phillips, Blythe, Gardner, y West, 2012](#)).

¹“Signals are defined as behavioral, physiological, or morphological characteristics fashioned or maintained by natural selection because they convey information to other organisms”

El proceso de ritualización En los animales consiste en que un comportamiento que originalmente tenía otra función, o no tenía una función adaptativa, se asocia con una respuesta adaptativa de otro individuo. La ritualización implica simplificar, exagerar y estereotipar comportamientos, haciéndolos más eficaces y reconocibles como señales.

Un ejemplo de proceso de ritualización es el de marcar el territorio con orina o heces. Este comportamiento, que originalmente servía para eliminar los desechos corporales, se ha convertido en una señal de comunicación entre los animales de una misma especie o de especies diferentes. Al marcar el territorio, el animal transmite información sobre su identidad, su estado reproductivo, su salud y su disposición a defender su territorio. De esta manera, puede evitar conflictos con otros individuos y advertirles de las consecuencias si lo ignoran.

la ritualización es un proceso importante en la comunicación animal que permite la transmisión de información vital para la supervivencia y el éxito reproductivo.

Lo mismo sucede en el caso de los algoritmos genéticos, cuando un comportamiento inicialmente utilizado por un agente artificial para otro propósito o simplemente presente de forma aleatoria, se vuelve una señal reconocida y utilizada por otros individuos.

Señal confiable y engañosa La comunicación animal implica el uso de señales que transmiten información sobre el estado del mundo al receptor. En este contexto, la confiabilidad de las señales se refiere a que el mensaje transmitido por el emisor coincide con el estado del mundo y resulta beneficioso para el emisor. Por otro lado, el engaño en las señales se refiere a cuando el emisor intenta obtener una ventaja a través de la transmisión de información errónea o exagerada sobre el estado del mundo con el objetivo de obtener una ventaja en su aptitud (Scott-Phillips y cols., 2012). Estas conductas no están vinculadas con la moralidad humana Searcy y Nowicki (2005) y pueden darse tanto entre individuos de la misma especie como entre individuos de diferentes especies. Por ejemplo, una planta, como ciertas orquídeas (Schiestl, 2005), puede emitir señales químicas para atraer polinizadores, y estas pueden ser tanto confiables como engañosas dependiendo de si hay flores y néctar disponibles o no. Asimismo, una señal emitida por un animal para alertar a otros sobre la presencia de un depredador puede ser confiable para algunos de sus congéneres, pero engañosa para individuos de otras especies que puedan beneficiarse de la presencia del depredador. Cabe mencionar que el engaño en las señales puede tener consecuencias negativas para el emisor, como la pérdida de visitas de polinizadores en el caso

de las plantas o el gasto de energía y tiempo innecesarios en el caso de los animales.

Efecto de la barba verde Los genes de la barba verde son aquellos que se utilizan para indicar el parentesco entre individuos de la misma especie. Estos genes pueden expresarse de manera bastante llamativa, como en el caso de la barba verde mencionada por Dawkins (Dawkins, 1976), lo que facilita su identificación por otros miembros de la especie. Aunque estos genes se han encontrado experimentalmente en algunos tipos de hormigas (Keller y Ross, 1998), bacterias (Queller, 2003) y reptiles (Sinervo y cols., 2006), y hay evidencia que sugiere su existencia en mamíferos (Summers y Crespi, 2005), es posible que también existan en otras especies.

La expresión de los genes de la barba verde podría tener un papel importante en la cooperación y la evolución de las especies. Estos genes permiten que los individuos reconozcan a sus parientes a través de una señal fenotípica, como el color de la barba. De esta manera, los individuos que comparten un mayor porcentaje de genes de la barba verde pueden ser más propensos a cooperar entre sí, ya que tienen un mayor interés en el éxito reproductivo de sus parientes. Esto podría conducir a un aumento en la aptitud reproductiva de dichos individuos y, en consecuencia, a una mayor cantidad de individuos con dichas características en el acervo genético.

Altruismo El altruismo se define como una conducta de cooperación que implica un costo para la aptitud reproductiva del individuo que la realiza, según la definición propuesta por Floreano (Floreano y cols., 2008). Esta conducta puede resultar paradójica desde el punto de vista evolutivo, pues se esperaría que cada individuo actuara en su propio beneficio y maximizara su aptitud reproductiva. No obstante, la teoría de la selección por parentesco puede explicar este fenómeno. De acuerdo con esta teoría, los individuos tienden a realizar actos de altruismo hacia aquellos con los que comparten genes, pues esto puede favorecer la difusión de sus propios genes en la especie. Así, aunque el individuo que coopera asume un costo a nivel individual, su descendencia, al compartir genes con el individuo beneficiado, puede obtener una ventaja a nivel del reservorio genético de la especie. Por lo tanto, el altruismo puede ser una estrategia evolutivamente estable en determinadas circunstancias y contextos.

Altruismo vs. Cooperación Es importante distinguir entre el altruismo y la cooperación. En la cooperación, aunque existe la conducta de ayudar a otro individuo, esta se da debido a que el individuo que proporciona dicha

ayuda o cooperación obtiene una ganancia al realizarla. Está demostrado que la cooperación es una estrategia evolutivamente estable en ausencia de altruismo, como se ha demostrado mediante el dilema del prisionero y simulaciones computarizadas (Axelrod y Hamilton, 1981).

2.2. Redes neuronales artificiales

Las redes neuronales artificiales (ANN, por sus siglas en inglés) son arquitecturas computacionales inspiradas en las redes neuronales biológicas (Mehrotra, Mohan, y Ranka, 1997). Los primeros en teorizar sobre su posibilidad y sentar las bases matemáticas para el modelo de una neurona fueron McCulloch y Pitts (McCulloch y Pitts, 1943). Dichos trabajos dieron origen a los primeros modelos de neuronas, los cuales se basaban en la lógica de umbral. Estos podían recibir entradas binarias y producir salidas binarias mediante una función de umbral, también conocida como función de escalón. Estos sistemas permitían realizar operaciones lógicas.

Sin embargo, una arquitectura de una sola neurona y sin pesos en sus entradas resultaba demasiado limitada para resolver muchos problemas prácticos existentes (Mehrotra y cols., 1997). Existen tres innovaciones fundamentales que sientan las bases de las redes neuronales contemporáneas. En primer lugar, la introducción del perceptrón por parte de Rosenblatt (Rosenblatt, 1958), el cual permite asignar pesos a cada una de las entradas de la neurona y con ello realizar tareas de clasificación. En segundo lugar, la evolución del perceptrón al perceptrón multicapa, el cual permite añadir capas de neuronas conectadas entre sí. Por último, los trabajos de Werbos (Werbos, 1974) junto con el desarrollo del método de retropropagación del error, como método de entrenamiento.

Las redes neuronales contemporáneas se utilizan para múltiples propósitos, como la clasificación de patrones, la categorización, la aproximación de funciones, la predicción, la optimización y el control (Jain, Mao, y Mohiuddin, 1996). En términos generales, las ANN contemporáneas se componen de tres elementos básicos: las neuronas, también conocidas como nodos; la función de activación, conocida como función de propagación; y las conexiones o pesos de la red.

Neurona artificial Las neuronas artificiales o nodos de la red intentan modelar de forma abstracta algunas de las funciones de sus contrapartes biológicas. En términos generales, estos nodos reciben la suma de una o más entradas multiplicadas por el peso de sus respectivas conexiones. A conti-

nuación, producen un valor de salida que se considera análogo al potencial de acción o frecuencia de disparo de una neurona real (Mehrotra y cols., 1997). Esto simula la forma en que las neuronas biológicas envían señales eléctricas a través de su cuerpo y a otras células nerviosas. Esto permite que las redes de neuronas artificiales sean utilizadas como una forma de procesar y transmitir información de manera similar a como lo hace el cerebro humano.

Otras características de las neuronas artificiales incluyen la capacidad de aprender y mejorar su rendimiento a través del entrenamiento, la utilización de capas ocultas para introducir abstracción en el procesamiento de información, y la utilización de técnicas de regularización para evitar el sobreajuste. Las redes neuronales son una forma de organizar y conectar las neuronas artificiales en una estructura jerárquica y en capas para realizar tareas complejas de procesamiento de información.

Función de activación La función de activación es un intento de modelar de forma abstracta el potencial de acción o frecuencia de disparo de las neuronas biológicas. Esta función se encarga de recibir la sumatoria de las entradas de la neurona multiplicadas por sus pesos de conexión y procesarlas para producir una salida (Mehrotra y cols., 1997). Si bien la función de activación sigmoide es la más común (Jain y cols., 1996), existen varios tipos de funciones de activación que se utilizan en las redes neuronales, entre las que se incluyen:

- La función sigmoide es una función no lineal que toma valores de entrada en un rango de $(-\infty, +\infty)$ y los mapea en un rango de $(0, 1)$. Es utilizada a menudo en la capa de salida de redes neuronales para problemas de clasificación.
- La función ReLU (Rectified Linear Unit) es una función no lineal que toma valores de entrada en un rango de $(-\infty, +\infty)$ y los mapea en un rango de $(0, +\infty)$. Es muy popular por su rapidez de cálculo y porque ha demostrado buen rendimiento en muchos problemas de aprendizaje profundo.
- La función tangente hiperbólica es una función no lineal que toma valores de entrada en un rango de $(-\infty, +\infty)$ y los mapea en un rango de $(-1, +1)$. Es utilizada a menudo en la capa de salida de redes neuronales para problemas de clasificación multiclase.
- La función Softmax es una función no lineal que toma valores de entrada en un rango de $(-\infty, +\infty)$ y los mapea en una distribución

de probabilidad sobre N clases. Es utilizada a menudo en la capa de salida de redes neuronales para problemas de clasificación multiclase.

- La función de activación llamada función de escalón es una función no lineal que recibe valores de entrada en un rango de $(-\infty, +\infty)$ y los procesa para producir una salida en un rango de $(0, 1)$. Es comúnmente utilizada en redes neuronales para problemas de clasificación binaria, ya que produce una salida de 1 para entradas mayores a un umbral específico y una salida de 0 para entradas menores a este. Es importante tener en cuenta que esta función no es derivable en el punto de corte, lo que puede dificultar el proceso de entrenamiento de la red neuronal.

Conexiones Las conexiones sirven para conectar las salidas de una o varias neuronas con la entrada de otras. Cada neurona puede tener varias entradas y salidas, y el número de entradas y salidas de una neurona puede variar según la arquitectura y el tamaño de la red. Cada una de estas conexiones en la red está determinada por un peso.

Los pesos de las conexiones en una red neuronal son valores numéricos asignados a cada una de las conexiones entre las neuronas de la red. Estos pesos indican la importancia o intensidad de la información transmitida a través de la conexión. Generalmente, cuanto mayor es el valor del peso de una conexión, mayor es la influencia de la información transmitida a través de ella.

Durante el entrenamiento de una red neuronal, los pesos de las conexiones se ajustan para minimizar el error entre la salida deseada y la salida producida por la red. Esto puede conseguirse utilizando algoritmos de optimización como el descenso gradiente o los algoritmos genéticos, que utilizan principios de evolución para optimizar los pesos de conexión. Es importante señalar que los pesos de conexión son uno de los factores que determinan la capacidad de una red neuronal para aprender y generalizar patrones en los datos. Por tanto, el ajuste adecuado de los pesos de conexión es esencial para el buen funcionamiento de una red neuronal.

2.2.1. Transmisión de información en redes *feedforward*

Las redes neuronales *feedforward* son consideradas la forma más común de redes neuronales (Jain y cols., 1996; Svozil, Kvasnicka, y Pospichal, 1997). Se trata de un perceptrón multicapa que puede ser arbitrariamente complejo, es decir, el número de capas y nodos de la red varía según la tarea que se intenta resolver.

Existen tres tipos de capas en una red feedforward: la primera capa de la red se conoce como **capa de entrada**. Esta recibe la información que se desea procesar. La última capa se conoce como **capa de salida**. Esta proporciona el resultado o salidas de la red neuronal. Las capas intermedias se conocen como **capas ocultas**. Estas solamente reciben y envían información desde y hacia otras capas de la red.

$$s_i = f_i\left(\sum_{j=1}^n w_{ij}x_j - \beta\right) \quad (2.1)$$

Donde s_i corresponde a la salida del nodo i , f es la función de activación de la neurona, w_{ij} es el valor de la conexión entre las neuronas i y j , y x_j es la activación proveniente de las neuronas de la capa anterior.

En las redes *feedforward*, a diferencia de las redes recurrentes donde cualquier neurona puede conectarse con cualquier otra neurona de la red, las conexiones entre las neuronas solo se dan entre capas subsecuentes. Es decir, en una red *feedforward*, los nodos pertenecientes a la capa "n" solo pueden tener conexiones con los nodos pertenecientes a la capa "n + 1". Así, la actividad de la red se propaga desde la capa de entrada hasta la capa de salida, pasando por cada una de las capas ocultas, pero no en dirección contraria.

La actividad de la red se propaga como resultado de pasar por una función de activación, cuyo resultado es la sumatoria de la actividad de las neuronas de la capa anterior (o las entradas en el caso de la primera capa) multiplicada por sus correspondientes conexiones, menos un *bias* β que puede o no utilizarse. La fórmula correspondiente a esta propagación se muestra en la ecuación 2.1.

2.2.2. Aprendizaje supervisado y no supervisado

Existen diversos métodos de aprendizaje máquina para realizar el entrenamiento de una red neuronal artificial. Estos se pueden dividir, *grosso modo*, en métodos supervisados y no supervisados.

Se consideran como métodos supervisados aquellos en los que, durante el entrenamiento de la red o algoritmo, se le proporcionan ejemplos conformados por pares, siendo uno de los elementos de dicha pareja la entrada de la red y el otro la salida que esta debería generar para ese ejemplo específico. El algoritmo que realiza el aprendizaje supervisado se encarga de tomar estos ejemplos e inferir una función que permita, a partir de una entrada,

producir la salida deseada. Idealmente, dicho algoritmo debe ser capaz de generar la salida deseada de entradas que nunca se le presentaron durante el proceso de aprendizaje, es decir, debe ser capaz de generalizar lo aprendido. El método más utilizado para realizar este proceso se conoce como retropropagación del error.

Dado que nuestro interés en esta tesis es modelar de una manera biológicamente plausible el surgimiento y evolución de conductas altruistas, no utilizaremos técnicas de aprendizaje supervisado.

En contraste con el aprendizaje supervisado, el aprendizaje no supervisado se caracteriza por no proporcionar al algoritmo o red neuronal ejemplos previamente etiquetados, sino que se le da la tarea de encontrar patrones o relaciones dentro de los datos por sí mismo. Algunos ejemplos de métodos de aprendizaje no supervisado son:

- **Clustering:** Este método se enfoca en agrupar los datos en subconjuntos de manera que los datos dentro de un mismo subconjunto sean similares entre sí y diferentes a los datos del resto de los subconjuntos. Algunos ejemplos de algoritmos de clustering son: k-means, agrupamiento jerárquico y DBSCAN.
- **Reducción de dimensionalidad:** Este método tiene como objetivo reducir la cantidad de variables de los datos a una cantidad menor, manteniendo la mayor información posible. Algunos ejemplos de algoritmos de reducción de dimensionalidad son: PCA, LLE y t-SNE.
- **Mapas autoorganizados:** Este método se enfoca en representar los datos en un espacio bidimensional de tal manera que los datos similares estén cerca entre sí. Un ejemplo de algoritmo de mapas autoorganizados es el SOM.

En general, el uso de métodos de aprendizaje no supervisado puede ser ventajoso en situaciones donde no se cuenta con etiquetas previas para los datos o cuando se desconoce el número de clases o grupos a los que pertenecen los datos. Además, estos métodos son útiles para la visualización y comprensión de los datos, así como para la detección de patrones ocultos en los mismos.

2.2.3. SOM

Los mapas autoorganizados (**SOM** por sus siglas en inglés) son un tipo de red neuronal de aprendizaje no supervisado formulada por [Kohonen \(1997\)](#) como una forma de modelar de manera biológicamente plausible,

simple y eficaz el proceso de aprendizaje. Los **SOM** están vagamente inspirados en el funcionamiento de las cortezas visuales y áreas somatosensoriales de los mamíferos.

En su forma más simple, un **SOM** produce un grafo de similitud de los datos entrantes, convirtiendo relaciones no lineales y de alta dimensionalidad en relaciones geométricas entre los nodos distribuidos en una rejilla llamada mapa. Esta rejilla tradicionalmente es de forma rectangular y de 2 dimensiones, aunque puede adoptar otras formas.

Algoritmo de entrenamiento del SOM

El entrenamiento de un SOM puede dividirse en dos fases o pasos computacionales [Saraswati, Hagenbuchner, Tsoi, y cols. \(2018\)](#): la fase de competencia y la fase de cooperación.

- **Fase de competencia:** Durante esta fase se toma aleatoriamente un vector de entrenamiento x del set de entrenamiento y se compara con todos los vectores guardados en cada uno de los nodos del SOM. Para este propósito, suele utilizarse la distancia euclidiana $|x - m_i|$ a cada uno de los nodos, buscando el nodo con la mínima distancia al vector de entrenamiento. El nodo con la menor distancia se conoce como nodo ganador w , el cual debe cumplir la siguiente igualdad: $w = \arg \min_{\forall i} |x - m_i|$.
- **Fase de cooperación:** En esta fase, el vector del nodo ganador m_w , así como el de sus nodos vecinos, son ajustados para parecerse más al vector de entrada x . Para ello, se usa un ratio de aprendizaje α que disminuye de forma progresiva en cada iteración $\alpha(t)$, así como una función de vecindad $f(\Delta_{wi})$, donde Δ es la distancia entre los nodos en el espacio del SOM. Para medir esta distancia, se suele usar la distancia euclidiana o Manhattan. Así, el cambio en un nodo se calcula de la siguiente forma: $\Delta_{mi} = \alpha(t)f(\Delta_{wi}) * (m_i - x)$.

Estas dos fases se iteran hasta alcanzar un número de iteraciones predefinido. El proceso de entrenamiento provoca que, mientras la posición topológica de las unidades del mapa se mantiene fija (las unidades m_i no se mueven en el espacio del SOM), los datos contenidos en cada uno de estos nodos cambian para representar mejor a los datos con los cuales se está entrenando al SOM. Según [Kohonen \(2001\)](#), esto permite comprimir la información mientras se conservan las relaciones topológicas y métricas existentes entre los datos.

Idealmente, esto provoca que los vectores de datos en este mapa se autoorganicen según el parecido que guardan entre ellos. Así, el vector de valores que guarda cada uno de los nodos del SOM se parecerá más o menos al resto de los nodos, dependiendo de la distancia a la que se encuentren del mismo en el espacio topológico del mapa. Mientras más cercanos sean dos nodos, más parecidos tendrán los vectores de datos que estos representan.

Una vez que el proceso de entrenamiento del SOM ha finalizado, este puede ser utilizado para asignar a una ubicación en el espacio del SOM vectores de entrada que no fueron utilizados durante el entrenamiento. Esto se hace comparando el vector de entrada con todos los vectores almacenados en el SOM y eligiendo al nodo con la menor distancia, que se conoce como nodo ganador. Además, el SOM también puede ser utilizado para visualizar patrones y agrupaciones en los datos de entrada, ya que los nodos del SOM que están cerca en el espacio del SOM suelen representar vectores de entrada similares.

2.3. Robótica cognitiva y Robótica evolutiva

La robótica cognitiva se ha presentado como una alternativa al enfoque tradicional de la inteligencia artificial, que concebía la inteligencia y la cognición como el procesamiento y manipulación de símbolos (Harnad, 1990; Newell y Simon, 1976). Mientras que la inteligencia artificial tradicional se enfocaba en la creación de sistemas que podían realizar tareas específicas de manera automatizada, la robótica cognitiva se centra en la creación de agentes artificiales que pueden realizar tareas cognitivas de manera autónoma y flexible. Esto se logra a través del modelado de las conductas propias de los agentes biológicos y sus procesos de aprendizaje, tal y como han sido entendidos desde las ciencias cognitivas (Lara y cols., 2018; Lara, Gaona, Escobar, Pardo, y Hermosillo-Valadez, 2020).

La robótica cognitiva se encuentra enmarcada en un enfoque conocido como cognición 4e, que incluye enactivismo, Corporeizada (*embodied*), Embebida (*embedded*) y extendida (*extended cognition*) (Menary, 2010). Enactivismo se refiere al papel central del cuerpo en el proceso cognitivo y el aprendizaje (Gonzalez-Grandón y Froese, 2018; Kiverstein y Clark, 2009). Corporeizada hace énfasis en la importancia del cuerpo en la cognición y el aprendizaje, mientras que Embebida se refiere a la interacción del agente con su entorno y cómo esto afecta su proceso cognitivo. Finalmente, cognición extendida se refiere a la idea de que la cognición no solo se limita al cerebro, sino que también se extiende a elementos externos como herramientas

o tecnología.

La robótica cognitiva ofrece una serie de ventajas en comparación con la inteligencia artificial tradicional. En primer lugar, permite la creación de sistemas que pueden adaptarse y aprender de manera autónoma a partir de su experiencia y del ambiente en el que se encuentran. Esto les permite realizar tareas de manera más eficiente y adaptarse a situaciones imprevistas de manera más rápida y efectiva. Además, la robótica cognitiva permite la creación de agentes que pueden interactuar de manera más natural y fluida con el mundo que les rodea, ya que tienen en cuenta el contexto y el ambiente en el que se encuentran (Valenzo, Ciria, Schillaci, y Lara, 2022).

El contexto es esencial para la robótica cognitiva, ya que permite a los agentes interpretar la información sensorial y adaptarse a situaciones imprevistas. La cognición no se desarrolla en un vacío, sino que está influenciada por el ambiente y las experiencias pasadas del agente. Por lo tanto, la robótica cognitiva se centra en la creación de sistemas que pueden percibir, comprender y actuar en el mundo de manera similar a como lo hacen los agentes naturales, teniendo en cuenta el contexto y el entorno en el que se encuentran.

Por lo tanto, la robótica cognitiva es una herramienta útil para el análisis de la cognición en los seres humanos y otros organismos vivos. Al permitir la investigación de agentes artificiales que exhiben comportamientos similares a los de los seres vivos, se logra una comprensión más profunda de la funcionalidad de los procesos cognitivos, tales como el aprendizaje, la percepción y la toma de decisiones. Asimismo, esta práctica puede tener aplicaciones en diversas disciplinas, tales como la psicología, la neurociencia y la biología.

Una de las sub-disciplinas de la robótica cognitiva es la robótica evolutiva, la cual se enfoca en el uso de algoritmos genéticos y otros procesos evolutivos para el diseño y optimización de agentes artificiales. En este campo, se busca crear agentes que puedan aprender y adaptarse de manera autónoma a partir de su interacción con el ambiente y la experiencia adquirida, siguiendo un proceso evolutivo similar al que se da en los organismos vivos. La robótica evolutiva posee aplicaciones en múltiples ámbitos, tales como la robótica móvil, la optimización de sistemas, la creación de controladores y la creación de agentes capaces de aprender y adaptarse de manera autónoma. Además, al modelar el proceso evolutivo, esta disciplina también puede contribuir al estudio de la evolución y la cognición en los seres vivos.

Los algoritmos genéticos son una valiosa herramienta para la robótica evolutiva, ya que permiten simular el proceso de selección natural y mutación que ocurre en la evolución biológica. Estos algoritmos funcionan de forma iterativa, comparando y evaluando diferentes soluciones para un pro-

blema específico. Luego, seleccionan las mejores soluciones y las mutan para crear nuevas soluciones, y así proseguir el proceso hasta encontrar una solución cercana a la óptima.

2.4. Algoritmos genéticos

Los algoritmos genéticos son un tipo de algoritmo de optimización que modelan de forma abstracta los procesos de la teoría sintética de la evolución. Fueron pensados como un método para encontrar soluciones eficaces a problemas de optimización y diseño cuya solución ideal se desconoce o resulta demasiado difícil de programar de forma predeterminada (Banzhaf y cols., 2006; Holland, 1975). Estos son muy útiles para resolver problemas de gran complejidad y se han utilizado en una amplia variedad de aplicaciones, incluyendo la inteligencia artificial y la robótica evolutiva. Pueden hallar soluciones óptimas o ligeramente subóptimas en un lapso breve, incluso para problemas con un espacio de solución amplio. Asimismo, pueden resistir variaciones en los parámetros del problema y pueden aplicarse a diversos problemas y entornos. Estas son algunas de las razones por las cuales son una de las técnicas más utilizadas en la inteligencia artificial y la robótica evolutiva (Harvey y cols., 1997).

A pesar de que existen infinidad de variaciones en la implementación de algoritmos genéticos, a grandes rasgos estos se pueden resumir en 6 pasos (ver **figura 2.1**):

1. Generar una población inicial de forma aleatoria.
2. Medir el desempeño (Aptitud) de cada uno de los individuos de la población para la realización de cierta tarea.
3. Utilizar algún método de selección basado en la aptitud de los individuos.
4. Reproducir a los individuos seleccionados
5. Aplicar operadores de mutación para producir la siguiente generación de individuos.
6. Ciclar los pasos del 2 al 5 hasta que la condición de paro se satisfaga.

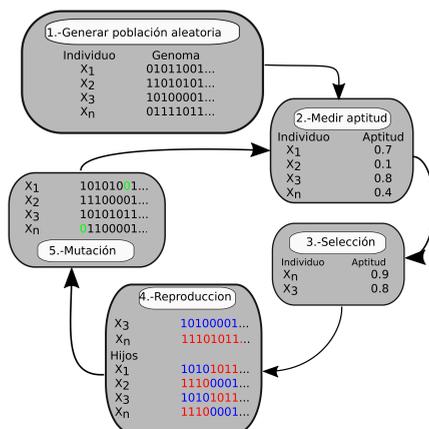


Figura 2.1: Representación esquemática de un algoritmo genético.

2.4.1. Representación de los individuos

Los algoritmos genéticos codifican la información de cada individuo en un genoma, que actúa como un equivalente del ADN de los organismos biológicos.

Una forma común de codificar la información de un individuo en un algoritmo genético es mediante un vector de números binarios, donde cada segmento de cierta longitud representa un gen y su valor numérico real es la expresión fenotípica de dicho gen. Sin embargo, esta no es la única forma de representación. También se pueden usar números reales, números enteros o conductas pre-programadas, dependiendo del problema a resolver y de las características deseadas.

Cada tipo de representación tiene sus ventajas y desventajas, que se reflejan en el equilibrio entre la explorabilidad y la explotabilidad del algoritmo. La explorabilidad se refiere a la capacidad del algoritmo de abarcar el mayor espacio de soluciones posible y evitar quedarse atrapado en óptimos locales. La explotabilidad se refiere a la capacidad del algoritmo de encontrar la mejor solución dentro de una región del espacio de soluciones. En general, hay una relación inversa entre ambas: a mayor explorabilidad, menor explotabilidad, y viceversa.

Por ejemplo, las conductas pre-programadas reducen el espacio de búsqueda y facilitan la convergencia rápida y eficiente del algoritmo, pero limitan la diversidad y la creatividad de las soluciones. En contraste, los núme-

ros reales permiten una mayor variedad y precisión de las soluciones, pero aumentan el espacio de búsqueda y dificultan la convergencia del algoritmo.

La representación binaria es comúnmente utilizada en conjunción con redes neuronales artificiales, ya que permite transformar las cadenas de binarios a números reales, que a su vez son utilizados como pesos de las conexiones de la red neuronal artificial del individuo al cual pertenecen (**figura 4.1**). Hemos elegido utilizar esta forma de representación por varias razones:

Se ha demostrado que la representación binaria ofrece una mayor explotabilidad del espacio de solución en comparación con otras representaciones utilizadas (Coello, 2004), sin comprometer la explotabilidad. Además, proporciona una buena analogía con lo que ocurre en los organismos biológicos, permitiendo distinguir claramente los genes de su expresión fenotípica.

La implementación de la representación binaria suele ser sencilla, ya que se puede realizar con poco código. Asimismo, permite una fácil comparación entre individuos mediante la distancia Hamming. Finalmente, es importante mencionar que la gran mayoría de investigaciones realizadas sobre este tema han utilizado este tipo de representación (Floreano y Keller, 2010; Floreano y cols., 2007, 2008; Mitri, Floreano, y Keller, 2009; Palacios-leyva, Aldana-franco, Lara-guzmán, y Montes, 2017; Waibel, Floreano, y Keller, 2011).

2.4.2. Métodos de selección

El método de selección es el proceso por el cual se eligen los individuos de una población que podrán reproducirse, basándose en su aptitud o desempeño. Se dividen en **métodos de selección duros**, basados en la ordinalidad, y **métodos de selección blandos**, basados en la proporción (Miller y Goldberg, 1996).

Métodos de selección duros

Los métodos de selección duros permiten que solo los mejores individuos puedan reproducirse. Estos métodos tienen la ventaja de preservar mejor las soluciones ya alcanzadas y llegar a un mínimo local más fácilmente. Sin embargo, tienen el problema de ocasionar una rápida pérdida de diversidad genética en la población, lo que puede causar la convergencia prematura del algoritmo (Miller y Goldberg, 1996). Algunos de los métodos de selección duros más conocidos son:

- Selección por truncamiento (elitista)
- Selección por torneo (dura)

Selección por truncamiento (elitista) Este método ordena a los individuos de acuerdo con su aptitud y selecciona a cierto porcentaje predefinido de ellos según su orden. Tiene una complejidad igual a $n \log n$. Es considerada una selección puramente elitista o dura, ya que solo los individuos con mejor aptitud de la población se reproducen. Los pasos para implementar este método son los siguientes:

Los pasos para implementar el método de selección por truncamiento (elitista) son los siguientes:

1. Ordenar los n individuos de la población de acuerdo a su aptitud.
2. Establecer el número de individuos a seleccionar multiplicando la proporción p de individuos por el número total de individuos n en la población (pn).
3. Seleccionar a los primeros pn individuos de la lista ordenada.

Selección por torneo Este método selecciona aleatoriamente individuos de la población para generar grupos de N individuos (lo más común es usar grupos de 2 individuos). En el caso de selección dura o determinista, el individuo con mejor aptitud es seleccionado, mientras que en el caso de selección blanda, se le asigna un porcentaje de selección a cada individuo. Por ejemplo, se podría asignar 70% de selección al mejor individuo y 30% de selección al individuo con menor aptitud. Los pasos para implementar este método son los siguientes:

1. Se forma un grupo x tomando aleatoriamente n individuos de la población.
2. Se ordenan los individuos del grupo x según su aptitud.
3. Se selecciona al individuo del grupo x . En caso de selección determinista, se selecciona al individuo con mejor aptitud, y en caso de selección blanda, se elige aleatoriamente al individuo que será seleccionado según la probabilidad asignada.
4. Se iteran los pasos del 1 al 3 hasta alcanzar la cantidad de individuos que se desea seleccionar.

El método de selección por torneo tiene la ventaja de considerarse eficiente al tener una complejidad de n , y puede usarse como un método de selección dura o blanda dependiendo de la cantidad de individuos que conformen los grupos para el torneo. A mayor cantidad de individuos, más dura será la selección y viceversa.

Métodos de selección blanda

Los métodos de selección blanda intentan solucionar el problema de la convergencia prematura y la pérdida de diversidad genética. Para ello, se emplean métodos estocásticos que permiten que incluso los individuos con una baja aptitud en la tarea puedan reproducirse. No obstante, estos métodos siguen favoreciendo la reproducción de individuos con la mejor aptitud. Algunos de los métodos blandos más conocidos son:

- Selección por ruleta
- Sobrante estocástico
- Selección por jerarquías
- Selección por torneo (blanda)

Selección por ruleta Fue propuesto por (De Jong, 1975, p.12-13) y es uno de los métodos más ampliamente utilizados en la robótica evolutiva. Este método se basa en asignar a cada individuo una probabilidad de ser elegido, proporcional a su aptitud en comparación con la del resto de la población, a la que se llama **valor esperado**. Este método puede describirse en los siguientes pasos:

1. **Calcular el valor total T** , sumando la aptitud de todos los individuos de la población.
2. **Calcular el valor esperado** de cada individuo usando una regla de tres para obtener el porcentaje de aptitud que aporta al total. Este número es el número de veces que dicho individuo debería reproducirse si su reproducción fuera perfectamente proporcional a su aptitud.
3. **Generar un número aleatorio r** entre 0 y el total de la aptitud.
4. **Recorrer la población de individuos sumando sus valores esperados** hasta que la suma sea igual o mayor a r . El último individuo cuyo valor esperado fue sumado se elige para ser reproducido.
5. **Iterar los pasos 2 y 3** hasta llegar a la cantidad de individuos que se desea seleccionar.

El procedimiento de ruleta posee la ventaja de mantener una elevada diversidad genética, al permitir que individuos con una baja aptitud puedan ser seleccionados. Por otro lado, tiene la desventaja de que incluso los

individuos con muy bajo desempeño pueden ser elegidos más de una vez, lo que hace que el algoritmo tarde más en converger en un mínimo local. Asimismo, se considera un método ineficiente para su uso en poblaciones grandes al tener una complejidad n^2 .

Selección por sobrante estocástico La selección por sobrante estocástico es una alternativa a la ruleta y tiene la ventaja de acercarse más a los valores esperados de cada uno de los individuos. Al igual que en la ruleta, este método asigna una probabilidad de ser elegido (**valor esperado**), siendo este proporcional a la aptitud de dicho individuo. El valor esperado se calcula sumando la aptitud de todos los individuos de esa población y determinando cuál es el porcentaje de ese total aportado por cada uno de ellos. Una vez que se tienen los valores esperados de la población, se toman los valores enteros de los mismos para realizar una ruleta y, posteriormente, se realiza otra ruleta con la parte fraccionaria. Este método se puede describir en los siguientes pasos:

1. **Calcular el valor total:** T . Para ello, se suman las aptitudes de todos los individuos de la población.
2. **Calcular el valor esperado:** usando una regla de tres, se calcula el porcentaje de aptitud que cada individuo aporta al total. Este número es el número de veces que dicho individuo debería reproducirse si su reproducción fuera perfectamente proporcional a su aptitud.
3. **Tomar la parte entera de los valores esperados:** se ordenan a los individuos en una lista.
4. **Generar un número aleatorio:** r entre 0 y la suma de la parte entera del valor esperado de todos los individuos.
5. **Recorrer la población de individuos sumando sus valores esperados:** hasta que la suma sea igual o mayor a r , el último individuo cuyo valor esperado fue sumado se elige para ser reproducido.
6. **Iterar los pasos 4 y 5:** hasta llegar a la cantidad de individuos igual a la suma de la parte entera del valor esperado.
7. **Tomar la parte fraccionaria de los valores esperados:** se ordenan a los individuos en una lista.
8. **Generar un número aleatorio:** r entre 0 y la suma de la parte fraccionaria del valor esperado de todos los individuos.

9. **Recorrer la población de individuos sumando sus valores fraccionarios:** hasta que la suma sea igual o mayor a r , el último individuo cuyo valor esperado fraccionario fue sumado se elige para ser reproducido.
10. **Iterar los pasos 8 y 9:** hasta llegar a la cantidad de individuos igual a la suma de la parte fraccionaria del valor esperado.

Este método tiene la ventaja de que la cantidad de veces que un individuo es seleccionado se aproxima mejor a su valor esperado. Sin embargo, debido a esto, también se provoca una convergencia más rápida que en la selección por ruleta. Al igual que el método de ruleta, su complejidad es n^2 , por lo que también se considera ineficiente para su uso con poblaciones grandes.

Selección por jerarquías Este método está basado en el método de ruleta, pero asigna el valor esperado de cada individuo basado en su jerarquía en lugar de su aptitud. Para ello, se ordenan a los individuos según su aptitud, desde el individuo con peor aptitud (el cual ocupa el puesto 1) hasta el individuo con mejor aptitud (el cual ocupa el puesto n). Este método se puede describir en los siguientes pasos:

1. **Ordenar los individuos de menor a mayor aptitud:** para establecer su puesto en p .
2. **Calcular el valor esperado de cada individuo:** con la siguiente fórmula: $ValExp = p(i)/n * (n - 1)$.
3. **Calcular el valor total T :** para ello, se suma el valor esperado de todos los individuos de la población.
4. **Generar un número aleatorio:** r entre 0 y T .
5. **Recorrer la población de individuos sumando sus valores esperados:** hasta que la suma sea igual o mayor a r , el último individuo cuyo valor esperado fue sumado se elige para su reproducción.
6. **Iterar los pasos 4 y 5:** hasta haber seleccionado el número de individuos deseados.

Este método tiene la ventaja de combatir de una forma más efectiva la convergencia prematura, al no asignar una probabilidad de ser elegido proporcional a la aptitud del individuo, sino a su jerarquía en la población. Al igual que el método de ruleta, tiene una complejidad de n^2 , lo cual puede ser un inconveniente al usarlo en poblaciones grandes.

La cruza se enfoca en modelar de forma abstracta y sencilla la recombinación genética que se produce en los sistemas biológicos durante la reproducción sexual. Se mezcla el genoma de dos individuos previamente seleccionados de la población para generar nueva descendencia. Este método se emplea en conjunto con la representación binaria de los individuos, aunque también se puede emplear con otros tipos de representaciones (Coello, 2004). Se considera como una estrategia para agrupar posibles soluciones parciales dentro del espacio de solución (Holland, 1992), así como un método para incrementar la variabilidad genética de una población, en contraposición a la opción de clonar a los individuos para generar descendientes. Existen tres principales métodos para realizar la cruza:

- **Cruza de un punto:** la cruza de un punto es la originalmente propuesta por (Holland, 1975). Consiste en tomar la cadena binaria que conforma el genoma de los individuos que se pretende reproducir, alinearlos el uno con el otro, fijar un punto para realizar la cruza (el cual suele ser el punto medio de dicha cadena) y tomar las dos mitades de la cadena de cada individuo producida por este corte para combinarla con la mitad opuesta del otro individuo. Esto produce dos nuevas cadenas que serán los descendientes de estos individuos. Se considera que una de las desventajas de este tipo de recombinación es que no permite crear todas las cadenas posibles dentro de un espacio de solución determinado; sin embargo, tiene la ventaja de que es bueno preservando las soluciones ya encontradas (Miller y Goldberg, 1996).

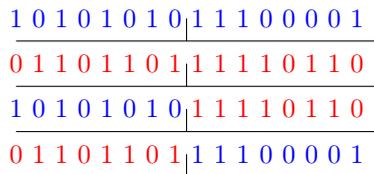


Figura 2.2: Proceso de cruza de un punto, Se alinean los genomas y se establece un punto para su cruza, se corta los genomas de cada uno de los individuos, se realiza la recombinación para generar 2 nuevos descendientes.

- **Cruza de dos puntos:** se lleva a cabo con el mismo procedimiento que la cruza de un punto, con la única diferencia de tener dos puntos de corte en los genomas de los individuos. Esto le permite solucionar el problema que presentan la cruza de un punto de no poder generar todas las combinaciones posibles de individuos, mientras que solo

realizar 2 cortes le permite ser lo menos destructiva posible con las soluciones ya encontradas.

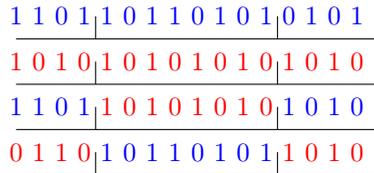


Figura 2.3: Proceso de cruce de dos puntos, Se alinean los genomas y se establece dos puntos para su cruce, se corta los genomas de cada uno de los individuos, se realiza la recombinación para generar 2 nuevos descendientes.

- **Cruza uniforme:** también conocida como cruce de N puntos, es similar a los dos tipos de cruce anteriores. La diferencia radica en que el número de cortes es mayor a 2 y no se fija previamente. Esto tiene la ventaja de explorar el espacio de solución de manera más eficaz, pero la desventaja de que tiende a destruir las soluciones previamente encontradas. Para abordar este problema, suele ir acompañada por una **probabilidad de cruce**, que determina la posibilidad de que la cruce ocurra o que simplemente se generen clones de los padres para producir la descendencia. Esta probabilidad suele fijarse en 0.5 (Coello, 2004).

- **Mutación:** La mutación es un proceso fundamental en los algoritmos genéticos que modela los fenómenos de mutación presentes en la evolución biológica. Se refiere a la probabilidad de que uno de los elementos de la cadena que conforma el genoma del individuo cambie. La mutación se considera una forma de mejorar la exploración del espacio de soluciones, ya que a mayor probabilidad de mutación, se explorará dicho espacio con mayor facilidad. Sin embargo, también puede ser destructiva para las soluciones ya encontradas. Por lo general, la probabilidad de mutación se ubica entre el 0.5% y el 2%. Es importante encontrar un equilibrio adecuado entre la exploración y la estabilidad de las soluciones para obtener buenos resultados con los algoritmos genéticos.

2.5. Estado del arte

La inspiración para este trabajo se deriva de los experimentos realizados por el laboratorio de Dario Floreano (Floreano y Keller, 2010; Floreano y cols., 2007, 2008; Mitri y cols., 2009). Todos estos experimentos siguen una estructura similar en la que se busca evolucionar de manera emergente la comunicación en agentes artificiales mediante el uso de algoritmos evolutivos. En estos experimentos, se emplea un entorno simulado que consta de dos comederos: uno con alimento y otro con veneno. Ambos comederos están equipados con una fuente de luz roja que permite a los robots localizarlos. La tarea se lleva a cabo con grupos de 10 robots móviles, los cuales tienen la capacidad de emitir luz azul. El objetivo de los robots es encontrar la fuente de comida y evitar el veneno. La aptitud de cada robot se calcula sumando el tiempo que pasa en la comida y restando el tiempo que permanece en el veneno.

La idea que subyace a dichos experimentos es lograr que los robots aprendan, por un lado, a señalar la fuente de comida o veneno por medio de la emisión de luz azul, y por otra parte, que los mismos aprendan que la luz azul es un indicador de la presencia de alimento o veneno, sin que la conducta de señalización o la de seguir o evitar la luz azul sea premiada explícitamente por el algoritmo evolutivo. Según los autores, esto representaría una conducta altruista por parte del robot que emite la señal, ya que al ser el espacio del comedero limitado, el avisar de su posición al resto de los robots iría en detrimento de la aptitud del robot que señala.

No obstante, a pesar de la gran relevancia de estos experimentos, es necesario volver a investigar el problema del altruismo en agentes artificiales. A pesar de que existen modelos matemáticos que explican su surgimiento en agentes biológicos, como la selección por parentesco, selección de grupo, reciprocidad directa, redes de reciprocidad y reciprocidad indirecta (Nowak, 2006), ninguno de los trabajos realizados dentro del área de la robótica evolutiva (ver el **cuadro 2.1**) ha logrado hacer surgir dicha conducta usando grupos de robots que no sean genéticamente iguales. A estas poblaciones, siguiendo dicha literatura, las llamaré a partir de aquí poblaciones homogéneas. A nuestro parecer, estos trabajos presentan fallas metodológicas y conceptuales que deberían ser corregidas. La idea es que modelando algunos factores evolutivos más, que han sido dejados de lado en investigaciones previas, se podría lograr hacerlo.

Consideramos que estudiar el altruismo usando como método el modelo de emisión de señales es un acierto Floreano y Keller (2010); Floreano y cols. (2007, 2008); Mitri y cols. (2009), y es algo que nos gustaría mantener

Artículo	Tipo de población	Se manipula la composición de las poblaciones	Controlador del robot	Simulación de la física	La tarea permite comunicación	Emerge comunicación	Emerge altruismo
Floreano y cols. (2007)	Heterogéneas y homogéneas	Sí	Red neuronal artificial	Sí	Sí	Sí en poblaciones homogéneas	Sí en poblaciones homogéneas y selección de grupo
Floreano y cols. (2008) (experimento 1)	Heterogéneas, homogéneas	Sí	Conductas programadas	No	No	No aplica	Sí en poblaciones homogéneas y selección grupo
Mitri y cols. (2009)	Heterogéneas	No	Red neuronal artificial	Sí	Sí	No	No
Floreano y Keller (2010) (Evolution of Cooperation and Altruism)	Heterogéneas y homogéneas	Sí	Red neuronal artificial	Sí	No	No aplica	Sí en poblaciones homogéneas
Floreano y cols. (2008) (experimento 2)	Heterogéneas y homogéneas	Sí	Red neuronal artificial	Sí	Sí	Sí en poblaciones homogéneas	Sí en poblaciones homogéneas y selección de grupo
Waibel y cols. (2011)	Parcialmente homogéneas	Sí	Red neuronal artificial	Sí	No	No aplica	Sí
Palacios-levya y cols. (2017)	Heterogéneas y homogéneas	Sí	Red neuronal artificial	Sí	Sí	Sí en poblaciones homogéneas	Sí en poblaciones homogéneas
Palacios-levya y cols. (2017)	Heterogéneas y homogéneas	Sí	Red neuronal artificial	Sí	Sí	Sí en poblaciones homogéneas	Sí en poblaciones homogéneas

Cuadro 2.1: Artículos relacionados

en nuestros estudios. Las razones de esta afirmación son:

1. La habilidad de señalar es una estrategia cognitiva que ha evolucionado en los organismos biológicos de forma independiente en incontables ocasiones, utilizando cualquier medio en el cual dichos organismos son capaces de emitir y recibir una señal: visión, olfato, electro recepción, tacto, oído y vibraciones (Cocroft y Rodríguez, 2005; Endler, 1993).
2. Se encuentran presentes en todos los tipos de organismos biológicos existentes Padje, Whiteside, y Kiers (2016).
3. La señalización de comida es una de las conductas de señalización más fiables existentes en los organismos biológicos.

2.5.1. ¿Por qué centrarnos en la señalización de comida?

La señalización de comida tiene la gran ventaja de ser muy fiable, a diferencia de las señales de alarma, advertencia o cortejo, donde hay casos muy estudiados de su uso engañoso, por mencionar algunos ejemplos:

- Se abusa de las señales de advertencia de especies venenosas mediante el mimetismo batesiano (Pfennig, Harcombe, y Pfennig, 2001).
- Las señales de alarma pueden ser utilizadas de forma engañosa para conseguir que los miembros de la propia especie se alejen de una fuente de comida en ausencia de un depredador (Møller, 2010).
- En el cortejo, los machos están interesados en exagerar sus cualidades para conseguir mejores hembras (Zahavi, 1977).

En cambio, en el caso de las llamadas para señalar que se ha encontrado comida, ya sean para compartirla, reclamar su propiedad o buscar apoyo del grupo, son altamente confiables Searcy y Nowicki (2005); Wauters, Richard-Yris, Pierre, Lunel, y Richard (1999). Esto se debe a que la señalización de comida contiene el costo implícito de indicar la posición de la misma a posibles competidores, lo cual, según la teoría del *hándicap*, es lo que mantiene a las señales confiables.

A pesar de que existen casos específicos de uso engañoso de estas señales para atraer hembras, esta dinámica no se presenta en un algoritmo evolutivo debido a que no modela el cortejo ni la selección sexual. Por lo tanto, resulta

más fácil analizar la confiabilidad de la señal. Además, el hecho de que la señalización de comida incluya, de manera directa o indirecta, un costo para la aptitud del individuo, la convierte en un candidato ideal para estudiar el fenómeno del altruismo. Todos estos factores sugieren que es factible investigar de manera eficiente las condiciones mínimas para el surgimiento del altruismo.

Estudiar el altruismo a través de la señalización de comida tiene otras ventajas. Una de ellas es que la señalización de comida es una conducta comúnmente observada en la mayoría de las especies animales, lo que permite una amplia generalización de los resultados obtenidos. Además, la señalización de comida es una conducta muy importante para la supervivencia y el éxito reproductivo de los individuos, lo que aumenta la relevancia evolutiva de estudiar la señalización de comida.

Otra ventaja es que la señalización de comida implica el compartir o proteger un recurso valioso, lo que permite analizar el papel del costo y la recompensa en la emisión de señales altruistas. Por último, al estudiar la señalización de comida es posible comparar el comportamiento de los individuos con diferentes grados de relación genética, lo que permite analizar el papel del parentesco en el surgimiento del altruismo.

2.5.2. Propuesta experimental

Tenemos la convicción de que al agregar la relación genética de los individuos al modelo inspirado en la barba verde y en la selección por parentesco propuesta por [Hamilton \(1963\)](#), podemos predecir el surgimiento de comportamientos altruistas en poblaciones de individuos. Según la regla de Hamilton, un modelo matemático que establece que si el parentesco entre el individuo que realiza una acción altruista y el individuo que la recibe, multiplicado por el beneficio que recibe el destinatario de la acción, es mayor que el costo de la acción para el individuo que la realiza, entonces el comportamiento altruista es una estrategia evolutivamente estable en esa población (**Fórmula 2.2**). El parentesco entre individuos puede influir en el surgimiento de conductas altruistas, ya que los individuos tienen un mayor interés en ayudar a individuos genéticamente similares a ellos, lo que puede aumentar la probabilidad de que sus genes se transmitan a las próximas generaciones.

Suponiendo que este principio también se aplique en poblaciones de agentes artificiales, deberíamos lograr el surgimiento de conductas altruistas en poblaciones con un acervo genético heterogéneo. Esto es diferente a los trabajos de [Floreano y Keller \(2010\)](#); [Floreano y cols. \(2007, 2008\)](#), que solo

logran evolucionar estas conductas en poblaciones homogéneas y no miden el efecto que tienen diversas proporciones de parentesco entre los individuos para decidir si ser o no altruistas con el otro.

$$RB - C > 0 \quad (2.2)$$

Regla de Hamilton, R=Parentesco entre el individuo que recibe la acción y el que la realiza, B=Beneficio para el que recibe la acción, C=Costo a la aptitud de aquel que realiza la acción altruista.

Con este propósito y como una primera aproximación al modelado de este fenómeno, realizamos experimentos con un diseño similar a los antes mencionados (Floareano y Keller, 2010; Floareano y cols., 2007, 2008), usando algoritmos genéticos y redes neuronales artificiales. La idea es lograr la evolución de la conducta de señalar una fuente de comida sin que dicha conducta sea premiada de forma explícita por la función de aptitud. Para ello, usaremos el simulador Enki y una versión simulada de los robots Epuck.

CAPÍTULO 3

Metodología

Como hemos mencionado anteriormente en este trabajo, utilizaremos algoritmos genéticos (**AG**), mapas autoorganizados (**SOM** por sus siglas en inglés) y un entorno simulado en nuestros experimentos.

3.1. Simulador y robots

Debido a la complejidad y al gran número de evaluaciones necesarias durante los procesos de optimización, a menudo resulta difícil llevarlas a cabo con robots reales en la mayoría de los algoritmos evolutivos. En consecuencia, las simulaciones se han convertido en una herramienta esencial para que los investigadores efectúen estas evaluaciones de forma eficaz y eficiente (Bongard, 2013).

Las simulaciones proporcionan un medio eficaz y eficiente para probar y evaluar algoritmos. Al simular la física de los entornos del mundo real, se pueden crear entornos virtuales que imitan con precisión el comportamiento de los robots reales. Además, las simulaciones permiten a los investigadores efectuar varias pruebas simultáneamente, lo que les permite explorar diversos escenarios y optimizar sus algoritmos rápidamente.

Debido a las características de nuestro algoritmo evolutivo y a la configuración de nuestros experimentos (Capítulo 4), así como al número de evaluaciones que necesitábamos realizar en cada uno de ellos, optamos por seguir el mismo camino. Esto implicaba llevar a cabo la evolución y evaluación de nuestros robots en un entorno simulado. Tras evaluar varios simuladores, elegimos el simulador Enki (Magenat y cols., 2009) y los robots E-puck.

3.1.1. Simulador

El software utilizado para todas las simulaciones de este trabajo es el simulador Enki, desarrollado por Magenat y cols. (2009). Este simulador está escrito en C++ y está diseñado específicamente para su uso en robótica evolutiva en entornos con superficies planas. Es capaz de simular de forma

limitada las colisiones y la física del entorno. Una ventaja de utilizar este simulador es que permite realizar simulaciones cientos de veces más rápido que en tiempo real. Además, al tratarse de un software de código abierto bajo licencia [Magnenat y cols. \(2009\)](#), nos permite modificar el código fuente del simulador y de los robots para adaptarlo a nuestras necesidades. Todas las simulaciones de este trabajo se realizan en un entorno simulado de 4 metros cuadrados.

3.1.2. Robots

Para nuestros experimentos, decidimos utilizar una versión simulada de los robots E-puck diseñados originalmente por [Mondada y cols. \(2009\)](#) con fines educativos. Utilizamos el modelo simulado de este robot incluido con el simulador Enki, que cuenta con sensores de infrarrojos, comunicación Bluetooth, dos ruedas con motores diferenciales, una torreta escáner y un anillo LED capaz de emitir luz de cualquier color. Modificamos este modelo para equipar a los robots E-puck con una cámara de 360 grados y un sensor de suelo capaz de detectar la región de interés en los experimentos. Además, modificamos el simulador para incluir esta región de interés en el escenario donde se realizan las simulaciones.

3.2. Mapas Auto Organizados (SOM)

Existen problemas relacionados con el uso de algoritmos genéticos, como el inmenso número de soluciones posibles a un problema dado, así como la alta dimensionalidad del espacio de soluciones. Esto dificulta la comprensión y visualización del movimiento de las soluciones en este espacio.

En este trabajo, decidimos utilizar mapas autoorganizados (**SOM**, por sus siglas en inglés) [Kohonen \(1997\)](#) tanto como un método de reducción de dimensionalidad para poder graficar nuestras poblaciones dentro de un espacio tridimensional, así como para asignar el color de los individuos en los experimentos relacionados con el modelado de la Barba verde (secciones 4.3, 4.4, 4.5 y 4.6).

Utilizar un SOM como método de reducción de dimensionalidad tiene varias ventajas:

- No requiere conocimiento previo de la estructura de los datos: El SOM puede autoorganizar la información de modo que los datos similares se agrupen sin necesidad de un conocimiento previo de cómo están organizados.

- Permite visualizar y comprender fácilmente la estructura de los datos: El SOM representa los datos en un espacio de menor dimensión, lo que facilita la visualización y el análisis de la estructura de los datos.
- Es robusto ante la alta dimensionalidad de los datos: El SOM puede organizar la información en un espacio de N dimensiones, independientemente de la dimensionalidad de la información que se esté organizando. Esto lo hace especialmente útil para trabajar con conjuntos de datos de alta dimensionalidad.
- Permite asignar colores en función del fenotipo: Cuando se utiliza un SOM, es posible asignar un color a cada nodo del mapa en función del fenotipo del individuo prototípico que representa. Esto permite una visualización más eficaz de las características fenotípicas individuales en el espacio tridimensional del SOM.

La implementación de nuestros mapas autoorganizados se realizó utilizando el lenguaje de programación CUDA C++, lo que tuvo varias ventajas. Una de ellas es que permite aprovechar el poder de procesamiento de las tarjetas gráficas (GPUs), que son procesadores diseñados especialmente para el procesamiento de datos en paralelo y que son ideales para tareas de alta intensidad de cálculo como la implementación de SOM. Al utilizar CUDA, es posible escribir código que se ejecute en la GPU en lugar de en la CPU, lo que permite aprovechar al máximo el poder de procesamiento de la GPU y obtener un rendimiento mucho mayor que con la CPU. Otra ventaja es que CUDA facilita el procesamiento en paralelo de datos, ya que proporciona un conjunto de herramientas y bibliotecas que permiten dividir el trabajo entre varios núcleos de la GPU de manera sencilla, lo que a su vez permite reducir el tiempo de cálculo y mejorar el rendimiento. Utilizar CUDA tuvo un impacto significativo en el tiempo de entrenamiento del SOM. Antes de utilizar CUDA, el entrenamiento del SOM tomaba aproximadamente 3 meses utilizando la CPU del ordenador. Sin embargo, al utilizar CUDA y aprovechar el poder de procesamiento de la GPU, el tiempo de entrenamiento se redujo a tan solo una semana. Esto se debe a que la GPU es mucho más rápida que la CPU para realizar cálculos en paralelo y es especialmente adecuada para tareas de alta intensidad de cálculo como el entrenamiento de un SOM. De esta manera, la utilización de CUDA nos permitió reducir drásticamente el tiempo de entrenamiento del SOM y hacer que nuestro proceso de investigación fuera mucho más eficiente.

3.2.1. Entrenamiento del SOM

La forma en que el **SOM** fue entrenado tanto para representar el espacio de solución, como para asignar un color a cada individuo, puede ser dividida en los siguientes pasos:

1. **Inicializar SOM.** Se generó un **SOM** de tres dimensiones con forma cúbica y un tamaño de $10 \times 10 \times 10$ nodos, para un total de 1000 nodos. Cada nodo contenía un vector de números reales entre -1 y 1, con el mismo tamaño del fenotipo de los individuos a organizar. Cada valor de los vectores fue generado de forma aleatoria, asegurándonos de que se tratara de un fenotipo posible, es decir, que cada uno de sus pesos pudiera ser representado en una cadena binaria de 4 bits.

Si bien existen diversas maneras de inicializar un SOM, se optó por inicializarlo de forma aleatoria debido a que desconocemos por completo cuál es la forma en que debían organizarse los fenotipos de nuestros robots en dicho espacio.

2. **Generar un ejemplo.** Para el entrenamiento del SOM, se generó aleatoriamente un genotipo representado como un vector de números binarios. Posteriormente, este valor fue convertido a su expresión fenotípica, la cual es un vector de números reales correspondientes a 4 bits del vector de números binarios. Este se conoce como vector de entrenamiento.
3. **Búsqueda del ganador.** Se tomó el vector de entrenamiento generado aleatoriamente y se midió la distancia euclidiana a cada uno de los 1000 nodos del **SOM**, con el propósito de encontrar el nodo con menor distancia euclidiana a nuestro vector de entrenamiento. A este se le conoce como nodo ganador “ w ”.
4. **Calcular la vecindad.** Se determinaron los nodos vecinos del nodo ganador mediante una función de vecindad (fórmula 3.1).

$$\beta(t) = \beta * e^{-1 \frac{j^i}{j^t}} \quad (3.1)$$

Función de vecindad, β es el valor de vecindad inicial, j^i el número de iteraciones actual y j^t el número total de iteraciones.

5. Se calcula el ratio de aprendizaje usando la siguiente función (**formula 3.2**)

$$\alpha(t) = \alpha \left(1 - \frac{j^i}{j^t}\right) \quad (3.2)$$

Ratio de aprendizaje α es el valor de aprendizaje j^i el número de iteraciones actual y j^t el número total de iteraciones.

6. El nodo ganador y sus vecinos cambian sus valores para parecerse un poco más al vector de entrenamiento. Este valor cambia dada la función de aprendizaje (fórmula 3.3).

$$\Delta w_j = \left(e^{-\frac{d^2}{2\beta(t)}}\right) * \alpha(t) * (x - w_j) \quad (3.3)$$

Función de aprendizaje. w es el vector de pesos del nodo a cambiar, d es la distancia euclidiana entre el nodo ganador y el nodo a cambiar en el espacio del SOM, x es el vector de entrenamiento y $\alpha(t)$ es el ratio de aprendizaje actual.

7. Los pasos del 3 al 6 se repitieron hasta terminar con todos los vectores de entrenamiento, un total de 3.5 millones de ejemplos para cada SOM entrenado.

Una vez entrenado, el SOM se guardó de forma permanente para utilizarlo tanto en la asignación de una posición a los individuos dentro del espacio de solución para el experimento 1, como en la asignación de un color a cada individuo durante el proceso evolutivo en los experimentos 2, 3, 4 y 5.

Experimentos y resultados

4.1. Experimento 1: Evolución de altruismo informando a los robots de su parentesco

El primer grupo de experimentos tenía como objetivo determinar si era necesario que los robots conocieran el vínculo de parentesco que mantenían con los individuos con los que interactuaban para evolucionar la conducta altruista, como sugiere [Hamilton \(1963\)](#). Para ello, se informó directamente a cada individuo del parentesco que mantenía con el resto de los individuos con los que interactuaba en determinado momento. El grado de parentesco se determinó usando la distancia Hamming entre los genomas de cada uno de los dos individuos, normalizándolo para producir un valor entre 0 y 1.

4.1.1. Entorno y robots

Los robots cuentan con una cámara de 360 grados, dos ruedas con motores diferenciales y una cámara orientada hacia el piso capaz de detectar la presencia de la región de interés bajo el robot. Además, cada robot cuenta con un anillo de luces LED que le permite emitir luz azul.

Red neuronal

Cada uno de los robots estaba controlado por una red neuronal artificial con una capa de entrada de 8 neuronas y una capa de salida de 3 neuronas (**Figura 4.2**). Cada neurona de la red utilizó una función de activación sigmoidea $(\frac{1}{1+e^{-x}} - 0.5) * 2$, donde x representa la sumatoria de la salida de las neuronas de la capa anterior multiplicada por el peso de su conexión a esa neurona, devolviendo valores entre -1 y 1 .

Capa de entrada Las primeras 6 neuronas de la capa de entrada percibían cada una la presencia de luz azul correspondiente a 60 grados del campo visual del robot, for a total of 360 grados. La séptima neurona recibía el valor de la cámara de piso, el cual era 1 cuando el robot se encontraba

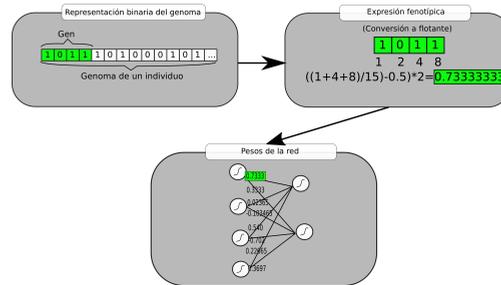


Figura 4.1: Esquema de la representación de un individuo en un algoritmo genético y la expresión fenotípica de sus genes como peso de una red neuronal.

sobre una región con comida y 0 en cualquier otra zona del entorno. La última neurona de la capa de entrada recibía el parentesco que dicho robot mantenía con el otro robot presente en el entorno. El peso de cada una de las conexiones de la red podía variar entre 1 y -1, lo cual permitía la existencia de conexiones que aumentan o suprimen la actividad de una neurona. El valor de dichas conexiones estaba determinado por los genomas de cada individuo.

Capa de salida La capa de salida estaba conformada por 3 neuronas. Las primeras 2 neuronas tenían la función de controlar cada uno de los motores, y su valor de salida se normalizó de -15 a 15 para obtener la velocidad de los mismos. Es importante señalar que, para facilitar la realización de la tarea, se decidió que las salidas de ambos motores tomaran un valor igual a 0 cuando el robot se encontrara sobre la región de interés. Por último, la tercera neurona controlaba la emisión de luz azul. Si el valor de salida era superior a 0, esto encendía el anillo de LEDs, mientras que si se presentaba un valor menor a 0, esto apagaba el anillo de LEDs.

Escenario

El entorno simulado tenía un tamaño de $2 m^2$ y contaba con una región de interés delimitada por un círculo gris de 30 cm de diámetro ubicado justo en el centro del entorno. Esta región de interés representaba una fuente de comida, y la aptitud del robot estaba directamente relacionada con el tiempo que pasaba sobre dicha región.

En cada una de las simulaciones con duración de 1200 ciclos, se colocaron

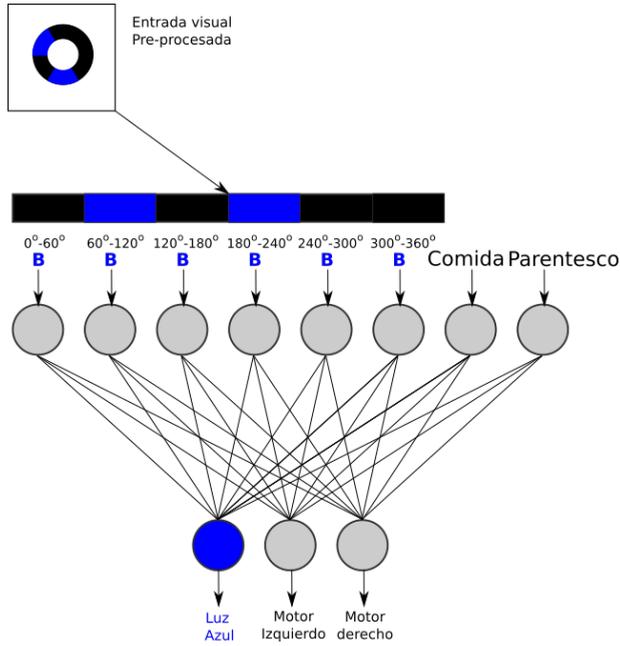


Figura 4.2: Red neuronal artificial que controlara a cada robot, A= Presencia de color azul, C=Zona del mapa donde el robot se encuentra, MD=Velocidad del motor derecho, MI=Velocidad del motor izquierdo, P=Parentesco del robot con el otro presente en el entorno.

dos individuos en el entorno. El primero de ellos se colocó justo en el centro del mapa dentro de la región de interés, mientras que el segundo aparecía en una orientación y posición aleatoria (**ver figura 4.3**). La idea era que la única forma en la que el robot que aparecía en una posición aleatoria conociera la posición de la región de interés era que el robot en la posición central la señalizara emitiendo luz azul. Esta conducta de emitir luz cuando se está sobre la región de interés es lo que consideraremos como una conducta altruista, ya que señalar la región de interés permitía al otro robot presente en la arena conocer la localización de la misma, lo cual disminuye las posibilidades de reproducirse del robot que emite la señal.

Cada robot de una generación realizó la tarea en ambos roles junto a cada uno de sus compañeros. Así, cada robot participó en 98 simulaciones de 1200 ciclos cada una: 49 donde fue el robot que aparecía en el centro de

Condiciones de evolución						
Cantidad de comida	1	1.2	1.4	1.6	1.8	2
Número de generaciones	250					
Número de individuos por generación	50					
Porcentaje de mutación	1.8 %					
Cantidad de procesos evolutivos	4					
Tipo de selección	Elitista 50 %					

Cuadro 4.1: Condiciones de evolución

la arena y 49 donde era el robot que aparecía en un sitio aleatorio.

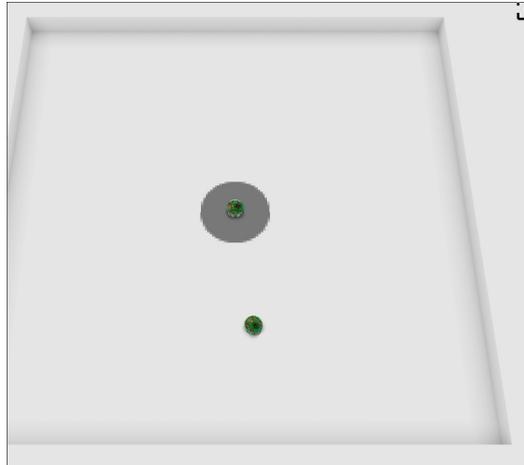


Figura 4.3: Entorno en donde se llevarán a cabo las simulaciones, en gris la región de interés, en verde los robots E-puck

4.1.2. Variables durante el proceso de evolución

Cantidad de comida y ciclos de vida La cantidad de comida presente en la región de interés fue la variable modificada en cada uno de los procesos evolutivos. Esta tomó valores de 1 a 2 con variaciones de 0.2 para cada condición (**ver cuadro 4.1**). Cada una de las simulaciones duró 1200 ciclos de 0.5 milisegundos.

	Variación de comida					
	2	1.8	1.6	1.4	1.2	1
Beneficio=	1	0.9	0.8	0.7	0.6	0.5
Costo=	0	0.1	0.2	0.3	0.4	0.5

Cuadro 4.2: Variación de beneficio y costo en relación con la cantidad de comida

Función de aptitud La función de aptitud que se utilizó (ver Fórmula 4.1) se diseñó de manera que cada robot que estuviera sobre la región de interés recibiera una parte proporcional del alimento disponible en dicha región, en cada ciclo de la simulación. No obstante, los robots no podían recibir más de una unidad de alimento por ciclo, lo que representaba la cantidad máxima que un robot podía ingerir en ese lapso. Esto permitía que (ver en el cuadro 4.2) solo con variar la cantidad de comida en la región de interés se pudiera modificar el beneficio y el costo de compartir el alimento con otro robot.

$$Aptitud\ Total = \sum_{i=0}^n (A_i = \begin{cases} (\frac{P_i * C}{R_i}) & \text{si } A_i < 1 \\ 1 & \text{en otro caso} \end{cases}) \quad (4.1)$$

P representa si el robot se encuentra o no en la región de interés, tomando el valor de 0 si el robot se encuentra fuera de esta y 1 si el robot se encuentra sobre ella. C representa la cantidad de comida en la región de interés, R representa la cantidad de robots en dicha región, y A representa la aptitud del robot durante un ciclo de vida.

Selección y cruza Para elegir los individuos más aptos, se aplicó un criterio elitista después de realizar las simulaciones. Solo se seleccionaron aquellos que obtenían los mejores resultados según la función de aptitud descrita anteriormente.

Elegimos un método de selección elitista, debido a que, las primeras generaciones donde la mayoría de los robots no pueden llegar a la región de interés y los que logran hacerlo lo hacen en un porcentaje pequeño de sus intentos. Dadas estas condiciones, nuestra función de aptitud incrementa la aptitud de los individuos cuando juegan el papel de señalizador a un 50% del valor teórico alcanzable, mientras el desempeño extra alcanzado por los robots de las primeras generaciones durante la tarea de forrajear es extremadamente bajo, aportando en el mejor de los casos unos cuantos puntos porcentuales a la aptitud del individuo, esto hace que todos los individuos

tengan una aptitud similar, y, por lo tanto, los métodos de selección como la ruleta o el sobrante sean incapaces de converger en una solución, lo cual se puede resolver utilizando el método elitista, pues no importa que tan pequeña sea la diferencia en la aptitud de los individuos este método garantizaba que se eligiese a los mejores individuos siempre.

No obstante, para minimizar el problema de una convergencia prematura asociada a este tipo de selección, minimizamos la dureza de este utilizando un porcentaje elevado de la población, el cual equivale a un 50% de esta población. Una vez elegidos los individuos se formaron una cantidad de parejas de forma aleatoria equivalentes al 50% de la población, donde cada individuo seleccionado para su reproducción formaba parte de 2 parejas distintas, cada una de ellas produjo 2 hijos que pasaron a formar parte de la generación siguiente, esto permite mantener una población de constante de robots a lo largo de todas las generaciones de puesto algoritmo evolutivo.

Mutación Los individuos pertenecientes a una nueva generación tuvieron una probabilidad de mutación del 1.8%, es decir, cada uno de los bits que componen su genoma tenía una probabilidad del 1.8% de cambiar de cero a uno y viceversa.

Duración del algoritmo y condición de paro El proceso evolutivo se utilizó para evolucionar los pesos de las conexiones de la red neuronal artificial encargada de controlar a los robots (ver figura 4.2). Cada uno de los procesos evolutivos contó con poblaciones de 50 individuos por generación. Debido a las características de la tarea, esperábamos un proceso de co-evolución dentro de nuestras poblaciones y que la conducta que queríamos medir fuera emergente, es decir, la capacidad de comportarse de forma altruista con otros robots. Por lo tanto, no podíamos asumir que la aptitud de nuestras poblaciones se incrementaría generación tras generación, y no tenía sentido utilizar un umbral de aptitud para decidir cuándo detener el algoritmo. Por este motivo, decidimos iterar nuestro algoritmo durante 250 generaciones para asegurarnos de que tuviera tiempo de converger en alguna conducta, independientemente de cómo se comportara la aptitud promedio de nuestras poblaciones. Para minimizar los efectos del azar en los resultados finales del proceso evolutivo, se evolucionaron de forma independiente 4 poblaciones por cada condición.

Lo que esperábamos, dada nuestra función de aptitud y parámetros de evolución, es que los robots aprendieran a encontrar la región de interés utilizando la única información disponible: la emisión de luz azul del robot que se encuentra en dicha región. También esperábamos que la conducta de

señalización disminuyera o aumentara en relación con la cantidad de comida en la región de interés y el parentesco entre el robot que señala y el robot que recibe la señal.

4.1.3. ¿Es la emisión de luz azul una señal altruista?

Durante el proceso evolutivo, no manipulamos el grado de parentesco de las poblaciones, por lo que pudieron haber surgido diversas estrategias para obtener un mejor desempeño en la tarea. Por lo tanto, una vez evolucionadas nuestras poblaciones de robots, es necesario efectuar pruebas para determinar el grado de altruismo alcanzado por cada una de las poblaciones evolucionadas, así como la relación entre la emisión de luz y la cantidad de alimento disponible durante la evolución, y su relación con el grado de parentesco de los individuos involucrados.

4.1.4. ¿Es la emisión de luz una señal confiable de comida?

Antes de evaluar si existía o no una conducta altruista, era preciso determinar si la emisión de luz azul dentro de la región de interés podía ser considerada una señal que anuncia la presencia de comida de forma confiable.

Para definir una señal, nos basaremos en la definición dada por [Otte \(1974\)](#) en el marco teórico:

“Signals are defined as behavioral, physiological, or morphological characteristics fashioned or maintained by natural selection because they convey information to other organisms”.

La definición es lo suficientemente abstracta como para no estar vinculada a ningún sustrato o canal específico, y es compatible con la teoría de la ritualización, que explica el surgimiento de conductas de señalización. Según [Searcy y Nowicki \(2005\)](#), una señal confiable debe cumplir con dos condiciones: estar consistentemente relacionada con un atributo del entorno o del emisor, y beneficiar al receptor. En este experimento, asumimos que la emisión de luz azul es una señal confiable si los individuos evolucionados logran encontrar la comida guiándose solamente por la luz azul emitida por el otro robot, sin recurrir a otras estrategias alternativas.

Parentesco percibido								
Comida	Beneficio	1	0.8	0.6	0.4	0.2	0	Costo
2	1	1	0.8	0.6	0.4	0.2	0	0
1.8	0.9	0.8	0.62	0.44	0.26	0.08	-0.1	0.1
1.6	0.8	0.6	0.44	0.28	0.12	-0.04	-0.2	0.2
1.4	0.7	0.4	.26	0.12	-0.02	-0.16	-0.3	0.3
1.2	0.6	0.2	0.08	-0.04	-0.16	-0.28	-0.4	0.4
1	0.5	0	-0.1	-0.2	-0.3	-0.4	-0.5	0.5
$rb - c =$								

Cuadro 4.3: En este cuadro se puede ver como cambia el resultado de aplicar en cada una de las 36 condiciones de prueba

4.1.5. Pruebas para determinar si la emisión de luz es una señal confiable de comida

Para verificar esto hicimos que los robots realizaran una tarea de forrajero (**figura 4.3**), bajo dos condiciones distintas; en la primera condición “luz encendida” el robot central siempre tenía la luz azul de su anillo de leds encendida, independientemente de la salida de su red. Mientras que en la segunda condición “a ciegas” el robot central tenía siempre apagado el anillo de leds independientemente de la salida de su red.

El objetivo de estos experimentos es comprobar si la luz azul es un indicador fiable de la presencia de alimento, y si al emitir esta luz sobre la zona de interés se está facilitando la localización del alimento a otro robot, lo que supondría una conducta altruista que disminuye la propia aptitud.

Para realizar los experimentos se emplearon seis grupos experimentales, formados por los 200 robots de la última generación de los individuos evolucionados bajo distintas cantidades de alimento (4 procesos evolutivos que generan 50 individuos cada uno). Cada grupo se identifica por la cantidad de alimento disponible en la zona de interés durante el proceso evolutivo, de modo que el grupo que evolucionó en un ambiente con 2 unidades de alimento se denomina “Comida 2.0”, el grupo evolucionado con 1.8 unidades de alimento “Comida 1.8”, y así sucesivamente para cada grupo.

Condición de luz encendida

Para evaluar el desempeño de las poblaciones evolucionadas, replicamos el mismo escenario, parámetros y procedimientos que se utilizaron durante

el proceso evolutivo. La única diferencia en este experimento fue que los robots que actuaron como señalizadores mantuvieron el anillo LED azul encendido durante toda la simulación, independientemente de la salida de la neurona que normalmente controlaba el anillo LED azul. Como en el proceso evolutivo, todos los robots realizaron la tarea alternando ambos roles con todos los demás robots de su población, lo que dio como resultado 98 simulaciones por robot, 49 como señalizador y 49 como forrajero. Dado que los robots que actuaron como señalizadores comenzaron sus simulaciones dentro de la región de interés, para esta prueba solo medimos el tiempo que los robots que actuaron como forrajeros pasaron dentro de esa región.

Condición a ciegas

Esta condición tenía como objetivo establecer un punto de referencia para evaluar si la población de robots previamente evolucionados utilizaba la luz azul como indicador para localizar la región de interés, o si recurrían a alguna estrategia no prevista por nosotros. Para ello, al igual que en la condición con luz encendida, empleamos el mismo escenario, parámetros y procedimientos que se usaron durante el proceso de evolución de los robots. La única diferencia era que el anillo de led azul de los robots que actuaban como señalizadores permanecía apagado durante todas las simulaciones. Al igual que en la prueba anterior, solo registramos el tiempo que el robot que actuaba como forrajero permanecía en la región de interés. Es importante destacar que los robots forrajeros iniciaban la tarea en una posición y orientación aleatorias, lo que nos permitía descartar que estos hubiesen "aprendido" la posición de la región de interés.

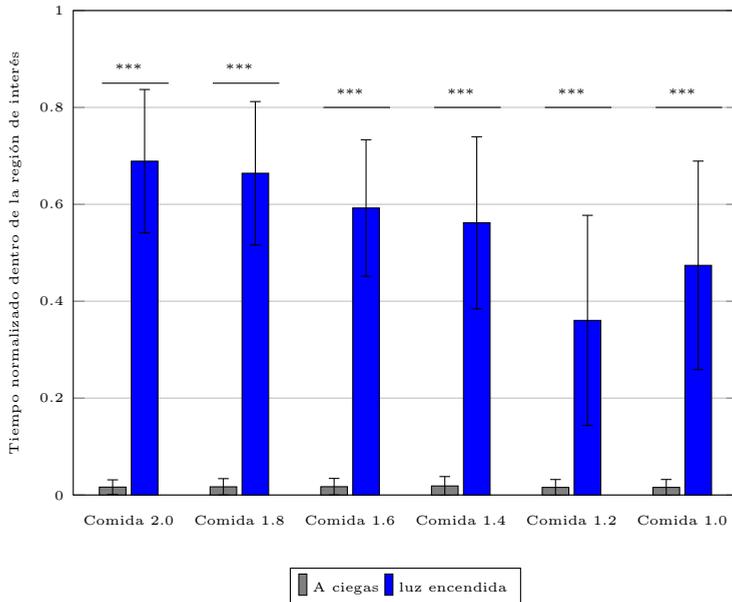


Figura 4.4: Diferencias entre las condiciones “luz encendida” y “a ciegas”, para cada uno de los grupos evolucionados usando 6 diferentes valores de comida, una prueba t de medidas repetidas fue realizada para ver las diferencias entre el número de ciclos que los robots pasan dentro de la región de interés para cada condición, los bigotes de la gráfica muestran la desviación estándar, *** $p < 0.05$.

Resultados estadísticos de las condiciones luz encendida y a ciegas

Para cada uno de los seis grupos se realizó una prueba t de medidas repetidas para comparar el número de ciclos normalizados que los robots pasan dentro de la región de interés cuando juegan el papel de forrajero, en la condición “a ciegas” comparada con la condición de “luz encendida” (figure 4.4).

Se encontraron diferencias significativas en el grupo *Comida 2.0* entre la cantidad de ciclos que los robots estuvieron dentro de la región de interés en la condición a ciegas ($M = 0.0163$, $SD = 0.015$) y la condición luz encendida ($M = 0.689$, $SD = 0.148$); $t(199) = -63.636$ $p < 0.05$.

Se encontraron diferencias significativas en el grupo *Comida 1.8* entre la cantidad de ciclos que los robots estuvieron dentro de la región de interés en la condición a ciegas ($M = 0.0169$, $SD = 0.0176$) y la condición luz encendida ($M = 0.6641$, $SD = 0.14801$); $t(199) = -62.132$ $p < 0.05$.

Prueba de altruismo						
Falso parentesco	1	0.8	0.6	0.4	0.2	0
Comida presente durante el proceso evolutivo	2	2	2	2	2	2
	1.8	1.8	1.8	1.8	1.8	1.8
	1.6	1.6	1.6	1.6	1.6	1.6
	1.4	1.4	1.4	1.4	1.4	1.4
	1.2	1.2	1.2	1.2	1.2	1.2
	1	1	1	1	1	1
Generaciones por grupo	4					
Individuos por generación	50					
Individuos por condicion	200					

Cuadro 4.4: Condiciones de prueba para determinar nivel de altruismo

Se encontraron diferencias significativas en el grupo *Comida 1.6* entre la cantidad de ciclos que los robots estuvieron dentro de la región de interés en la condición a ciegas ($M = 0.0174$, $SD = 0.0182$) y la condición luz encendida ($M = 0.6150$, $SD = 0.1648$); $t(199) = -50.962$ $p < 0.05$.

Se encontraron diferencias significativas en el grupo *Comida 1.4* entre la cantidad de ciclos que los robots estuvieron dentro de la región de interés en la condición a ciegas ($M = 0.01864$, $SD = 0.0194$) y la condición luz encendida ($M = 0.5619$, $SD = 0.1776$); $t(199) = -42.494$ $p < 0.05$.

Se encontraron diferencias significativas en el grupo *Comida 1.2* entre la cantidad de ciclos que los robots estuvieron dentro de la región de interés en la condición a ciegas ($M = 0.0157$, $SD = 0.01628$) y la condición luz encendida ($M = 0.3604$, $SD = 0.2169$); $t(199) = -22.69$ $p < 0.05$.

Se encontraron diferencias significativas en el grupo *Comida 1.0* entre la cantidad de ciclos que los robots estuvieron dentro de la región de interés en la condición a ciegas ($M = 0.01689$, $SD = 0.01634$) y la condición luz encendida ($M = 0.4740$, $SD = 0.2152$); $t(199) = -29.798$ $p < 0.05$.

De los resultados presentados se concluye que, en los 6 grupos evolucionados bajo distintas condiciones de comida, la luz azul en la región de interés es el factor principal que ayuda a los robots a encontrarla, lo que implica que los robots han aprendido durante la evolución que la luz azul es una señal de comida.

Esto es relevante porque se requiere que la emisión de luz dentro de la región de interés sea una señal de comida para que se considere conducta altruista. Esto se afirma con base en dos hechos: el primero es que los datos muestran que la luz azul del señalizador es el único indicio confiable para que

los robots localicen la región de interés, el segundo es que, según nuestra función de aptitud (**Equation 4.1**) si el señalizador facilita al forrajero encontrar la región de interés con la luz, esta conducta afecta negativamente su aptitud.

4.1.6. Pruebas para determinar el nivel de altruismo

Una vez que se comprobó que la emisión de luz es una señal de alimento y una conducta altruista en todas las condiciones de evolución para las 36 ejecuciones del algoritmo evolutivo (4 ejecuciones para cada una de las 6 condiciones), se quiso determinar si alguno de los robots evolucionados bajo las 6 distintas condiciones de presencia de alimento desarrollaron la conducta de señalar el alimento, y si, como la regla de Hamilton sugiere, esta conducta se relaciona con el nivel de parentesco.

Para realizar estas pruebas, se utilizó un diseño experimental 6×6 (6 niveles de parentesco \times 6 niveles de alimento), para cada una de estas condiciones experimentales, los grupos estuvieron formados por la última generación de cada algoritmo evolutivo (4 generaciones de 50 individuos por condición), para un total de 200 individuos por grupo.

Cada uno de estos grupos fue evaluado en las mismas condiciones en las que evolucionaron, es decir, que la región de interés contiene la misma cantidad de alimento que en el proceso evolutivo, y cada uno de estos grupos fue sometido a 6 distintos niveles de "falso parentesco" (**tabla 4.4**). Para generar este falso parentesco, se modificaron los valores de parentesco que la red neuronal de los robots recibe durante la simulación, independientemente del valor real que este tenga. Este parentesco falso varía en cada condición entre valores que van del 0 al 1 (**tabla 4.4**) en incrementos de 0.2 para cada condición, lo que nos da seis diferentes valores de falso parentesco para cada grupo experimental.

En esta prueba, al igual que en el proceso evolutivo, todos los robots desempeñan tanto el papel de señalizador como el de forrajero, interactuando con todos los robots de su misma generación. Esto implica un total de 98 simulaciones por individuo. El aspecto que queremos medir es el grado de emisión de luz azul cuando el robot está dentro de la zona de interés.

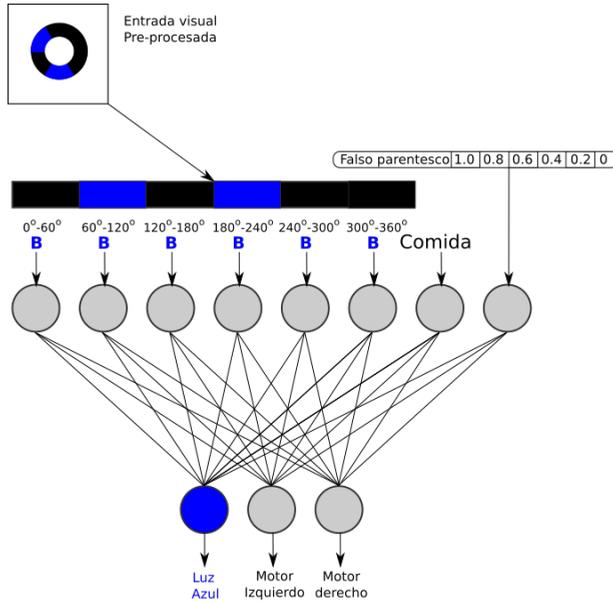


Figura 4.5: Arquitectura de la red neuronas de los robots utilizada durante las pruebas para determinar el nivel de altruismo, cada grupo experimental será sometido a 6 niveles distintos de falso parentesco.

4.1.7. Resultados estadísticos de la prueba de altruismo experimento 1

Para analizar el comportamiento de los robots altruistas (que emiten luz dentro de la región de interés) y su relación con el parentesco percibido, seleccionamos el 20% de individuos con mayor emisión de luz azul en cada grupo en las 6 condiciones. Realizamos una prueba ANOVA de medidas repetidas de una vía para evaluar si la emisión de luz azul estaba influenciada por el parentesco percibido.

En el grupo evolucionado con 2 unidades de comida, el ANOVA mostró un efecto significativo del parentesco en la emisión de luz azul, con un ajuste de Greenhouse-Geisser para corregir la violación de la esfericidad $F(1.4, 55) = 47, p < 0.05$.

Aplicamos una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo evolucionado con 2.0 unidades de comida en todas las condiciones de parentesco. Encontramos diferencias significativas $p < 0.05$ entre todas las condiciones, excepto entre el grupo

0.6 y 0.8 ($p = 0.053$), lo que sugiere que la emisión de luz azul está influenciada por el parentesco percibido en todas las condiciones, excepto en las condiciones de parentesco más cercanas.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	NS			
0.4	***	***	***		
0.2	***	***	***	***	
0	***	***	***	***	***

Cuadro 4.5: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 2.0 , ** $p \leq 0.05$, *** $p \leq 0.01$

El ANOVA de medidas repetidas para el grupo evolucionado con 1.8 unidades de comida revela un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés (el área donde se espera que se produzca la interacción social), según el ajuste de Greenhouse-Geisser $F(2.7, 107) = 72, p < 0.05$.

Mediante una prueba t de comparaciones múltiples con corrección de Bonferroni, se contrastaron los grupos evolucionados con 1.8 unidades de alimento y se hallaron diferencias significativas $p < 0.05$ entre todas las condiciones de parentesco, excepto entre las condiciones de parentesco 0.6 y 0.4 ($p = 0.095$). Se pueden consultar los detalles de estas comparaciones en la tabla 4.6.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	***	
0	***	***	***	***	**

Cuadro 4.6: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.8 , ** $p \leq 0.05$, *** $p \leq 0.01$

El ANOVA de medidas repetidas para el grupo evolucionado con 1.6 unidades de comida muestra un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés (el área donde se espera que se produzca la interacción social), según el ajuste de Greenhouse-Geisser $F(1.5, 60) = 28, p < 0.05$.

Mediante una prueba t de comparaciones múltiples con corrección de Bonferroni, se contrastaron los grupos evolucionados con 1.6 unidades de alimento y se hallaron diferencias significativas $p < 0.05$ entre todas las condiciones de parentesco, excepto entre las comparaciones de las condiciones con parentesco 1 y 0.8 ($p = 0.16$), y las comparaciones entre las condiciones con parentesco 0.4 y 0.6 ($p = 0.075$). Se pueden consultar los detalles de estas comparaciones en la tabla 4.7.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	NS				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	**	
0	***	***	***	***	***

Cuadro 4.7: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.6 , ** $p \leq 0.05$, *** $p \leq 0.01$

El ANOVA de medidas repetidas para el grupo evolucionado con 1.4 unidades de comida muestra un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés (el área donde se encuentra el alimento), según el ajuste de Greenhouse-Geisser $F(2.5, 96) = 29$, $p < 0.05$.

Mediante una prueba t de comparaciones múltiples con corrección de Bonferroni, se contrastaron los grupos evolucionados con 1.4 unidades de alimento y se hallaron diferencias significativas $p < 0.05$ entre todas las condiciones de parentesco (ver tabla 4.8), excepto entre las comparaciones de las condiciones con parentesco 0.6 y 0.8 ($p = 0.141$), y las comparaciones entre las condiciones con parentesco 0.4 y 0.6 ($p = 0.085$).

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	NS			
0.4	***	***	NS		
0.2	***	***	***	**	
0	***	***	***	***	***

Cuadro 4.8: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.4 , ** $p \leq 0.05$, *** $p \leq 0.01$

El ANOVA de medidas repetidas para el grupo evolucionado con 1.2 unidades de comida no muestra un efecto significativo del parentesco en la

emisión de luz azul dentro de la región de interés, ajuste de Greenhouse-Geisser $F(1, 40) = 5.3$, $p > 0.05$. Debido a la falta de significancia en la prueba ANOVA para esta condición, no se realizó la prueba t.

El ANOVA de medidas repetidas para el grupo evolucionado con 1.0 unidades de comida no muestra un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, ajuste de Greenhouse-Geisser $F(1.4, 77) = 0.84$, $p = 0.4$. Debido a la falta de significancia en la prueba ANOVA para esta condición, no se realizó la prueba t.

El ANOVA de medidas repetidas para el grupo evolucionado con 1.0 unidades de comida no muestra un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés (el área donde se espera que se produzca la interacción social), según el ajuste de Greenhouse-Geisser $F(1.4, 77) = 0.84$, $p = 0.4$. Debido a la falta de significancia en la prueba ANOVA para esta condición, no se realizó la prueba t.

Los datos analizados estadísticamente revelan tres aspectos relevantes:

En primer lugar, se demuestra que es factible inducir el surgimiento de conductas altruistas en agentes artificiales mediante algoritmos evolutivos que emplean poblaciones heterogéneas, simulando el parentesco y el gen de la barba verde.

En segundo lugar, se constata que esta conducta altruista se ajusta al modelo teórico propuesto por [Hamilton \(1963\)](#), ya que hallamos una relación entre el nivel de altruismo y el parentesco entre los individuos cuando la regla de Hamilton arroja valores superiores a cero. Esto se aprecia especialmente en los grupos de experimentación *Comida 2.0*, *Comida 1.8*, *Comida 1.6* y *Comida 1.4* (ver tabla 4.10), donde los valores obtenidos tras aplicar la regla de Hamilton son mayoritariamente positivos en la mayoría de las condiciones, mientras que en los grupos de experimentación *Comida 1.2* y *Comida 1.0* no hallamos esta relación entre el parentesco y la emisión de luz dentro de la región de interés. Esto es esperable porque, en la mayoría de las condiciones experimentales, la regla de Hamilton da resultados inferiores a cero en estos grupos. Incluso en los pocos casos en que el resultado es positivo, lo es solo de forma marginal (0.2 y 0.08 respectivamente). Esto sugiere que existe una correlación entre el nivel de altruismo y el nivel de parentesco entre los individuos y que la regla de Hamilton tiene un poder predictivo en este contexto.

En tercer lugar, se verifica que la conducta altruista evoluciona más fácilmente en condiciones de abundancia para los individuos.

Aunque el modelo implementado en este conjunto de experimentos presenta algunas limitaciones, como el hecho de que el parentesco se asigna de forma directa a cada individuo, y que la red neuronal que controla a los ro-

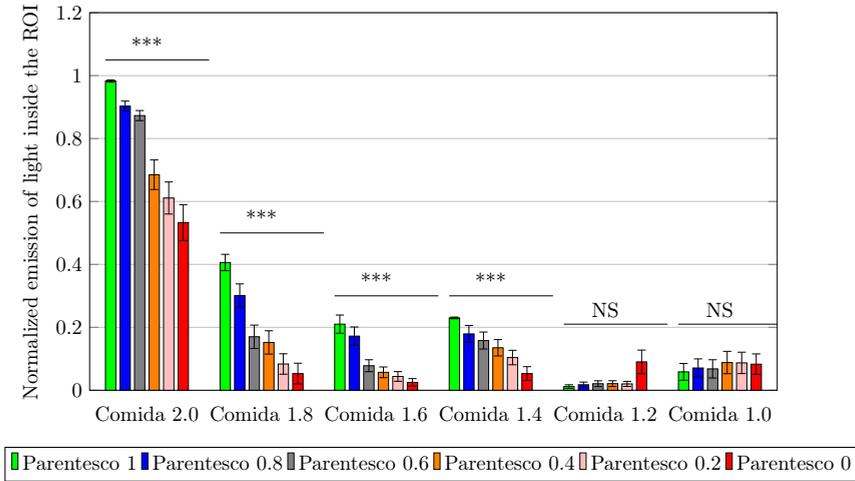


Figura 4.6: Diferencias de emisión de luz según el nivel de parentesco percibido para los 6 grupos evolucionados con distintas cantidades de comida, ANOVA de medidas repetidas, *** $p < 0.05$.

Comida	Parentesco 1	Parentesco 0.8	Parentesco 0.6	Parentesco 0.4	Parentesco 0.2	Parentesco 0
2.0	0.98274 ± 0.0034	0.903 ± 0.016	0.873 ± 0.016	0.685 ± 0.047	0.611 ± 0.041	0.532 ± 0.041
1.8	0.406 ± 0.026	0.301 ± 0.037	0.170 ± 0.037	0.152 ± 0.037	0.144 ± 0.036	0.140 ± 0.035
1.6	0.210 ± 0.029	0.172 ± 0.029	0.078 ± 0.019	0.057 ± 0.017	0.062 ± 0.016	0.062 ± 0.016
1.4	0.230 ± 0.0026	0.179 ± 0.027	0.158 ± 0.027	0.135 ± 0.027	0.132 ± 0.026	0.130 ± 0.026
1.2	0.01186 ± 0.00566	0.0175 ± 0.0086	0.0208 ± 0.0093	0.0150 ± 0.0088	0.0147 ± 0.0087	0.0144 ± 0.0086
1.0	0.0585 ± 0.0268	0.0708 ± 0.02894	0.068 ± 0.029	0.0457 ± 0.0244	0.0447 ± 0.0243	0.0440 ± 0.0242

Cuadro 4.9: Promedios de emisión para cada condición experimento 1

bots recibe la información visual totalmente pre-procesada, estos primeros experimentos constituyen un avance significativo para esta línea de investigación. Una vez demostrada la posibilidad del surgimiento del altruismo mediante la simulación de estos dos fenómenos, se puede incrementar la complejidad del modelo para acercarlo más a su contraparte biológica.

4.1.8. Graficar las poblaciones utilizando SOMs

En esta sección, se utiliza el Self-Organizing Map (SOM) como una herramienta para visualizar y analizar los resultados obtenidos con algoritmos genéticos. El SOM permite representar en un espacio tridimensional las poblaciones generadas por los algoritmos genéticos, a partir de los fenotipos (pesos de la red neuronal artificial) de cada individuo. Así, se puede observar

Prueba de altruismo, $rb - c =$						
Comida	Parentesco					
	1	0.8	0.6	0.4	0.2	0
2	1	0.8	0.6	0.4	0.2	0
1.8	0.8	0.62	0.44	0.26	0.08	-0.1
1.6	0.6	0.44	0.28	0.12	-0.04	-0.2
1.4	0.4	.26	0.12	-0.02	-0.16	-0.3
1.2	0.2	0.08	-0.04	-0.16	-0.28	-0.4
1.0	0	-0.1	-0.2	-0.3	-0.4	-0.5

Cuadro 4.10: En esta tabla podemos apreciar los resultados de aplicar la regla de Hamilton a cada uno de los seis grupos experimentales de robots bajo los seis diferentes niveles de parentesco, en rojo las condiciones donde los resultados son en mayoría menores que cero

la evolución y la distribución de dichas poblaciones en el espacio de solución del SOM. Esta metodología facilita la comprensión del proceso evolutivo de las poblaciones y sus relaciones. A continuación se describe el procedimiento seguido para realizar esta tarea y se muestran y comentan los resultados obtenidos.

Para representar en un espacio tridimensional cada una de las poblaciones generadas por los algoritmos genéticos, se empleó uno de los SOM's previamente entrenados para determinar la posición que cada individuo ocupa en este espacio. Se introdujeron los fenotipos (los pesos de la red neuronal artificial) de cada individuo como entradas del **SOM** y se asignaron las coordenadas correspondientes a su nodo ganador.

Una vez se obtuvieron las coordenadas de los individuos de cada una de las poblaciones mediante el SOM, se graficaron en una representación tridimensional del espacio de solución para observar cómo se comportaron dichas poblaciones a lo largo del tiempo durante su evolución. Para representar estos datos, se utilizaron gráficos de dispersión tridimensionales.

En las figuras (**Figs. 4.7, 4.8, 4.9, 4.10, 4.11 y 4.12**) se muestran los cambios en cada una de las condiciones experimentales en pasos de 50 generaciones. En estas figuras, se puede observar cómo las poblaciones evolucionan hacia soluciones cada vez más óptimas a medida que avanzan las generaciones. Además, se pueden identificar grupos de individuos con características similares en el espacio del SOM, lo que sugiere la existencia de subpoblaciones especializadas en diferentes tareas. Estos hallazgos son consistentes con la teoría evolutiva y demuestran la utilidad del SOM como herramienta de análisis en el contexto de la evolución de poblaciones

mediante algoritmos genéticos.

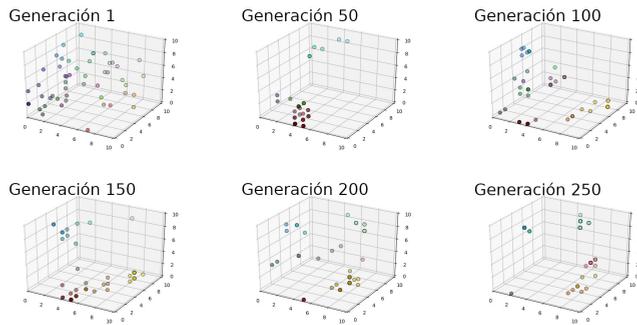


Figura 4.7: Poblaciones graficadas en el SOM para la condición Comida 1.0

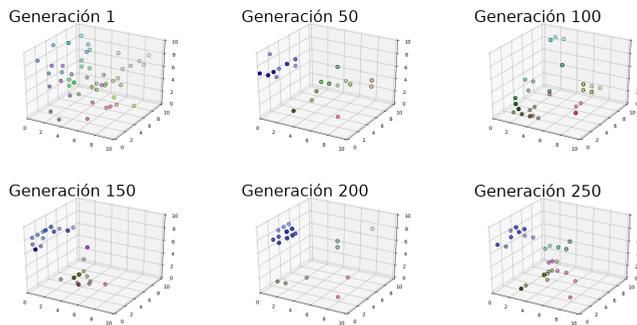


Figura 4.8: Poblaciones graficadas en el SOM para la condición Comida 1.2

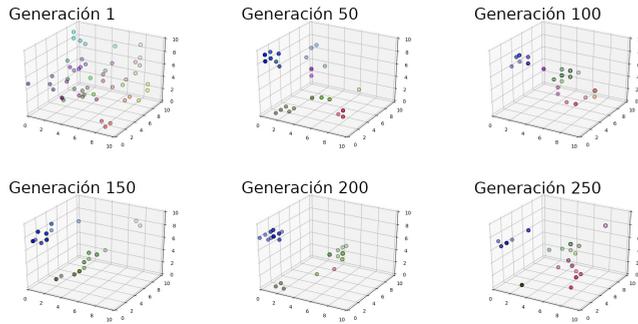


Figura 4.9: Poblaciones graficadas en el SOM para la condición comida 1.4

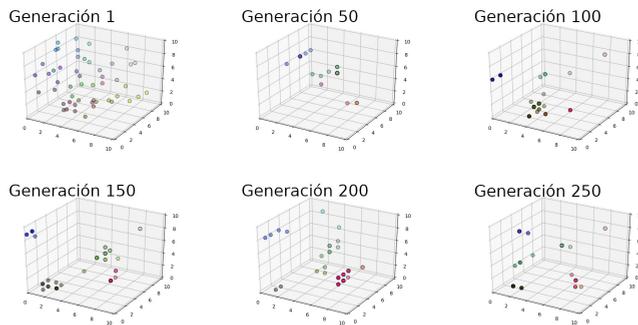


Figura 4.10: Poblaciones graficadas en el SOM para la condición Comida 1.6

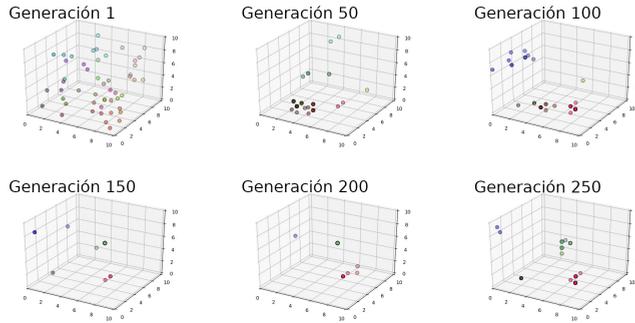


Figura 4.11: Poblaciones graficadas en el SOM para la condición Comida 1.8

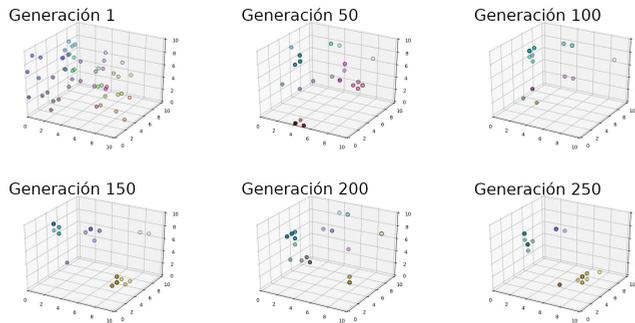


Figura 4.12: Poblaciones graficadas en el SOM para la condición comida 2.0

Podemos observar que en la primera generación de todos nuestros algoritmos evolutivos, los individuos se distribuyen al azar por el espacio de solución. Esto se debe a que se generan de forma aleatoria y todavía no han sufrido ninguna presión evolutiva. En las generaciones siguientes, se aprecia que los individuos se agrupan, formando conjuntos más o menos definidos. No obstante, hay que señalar que en ninguno de los procesos evolutivos realizados los individuos convergen en un solo conjunto o zona del espacio de solución.

Emisión dentro de la región de interés

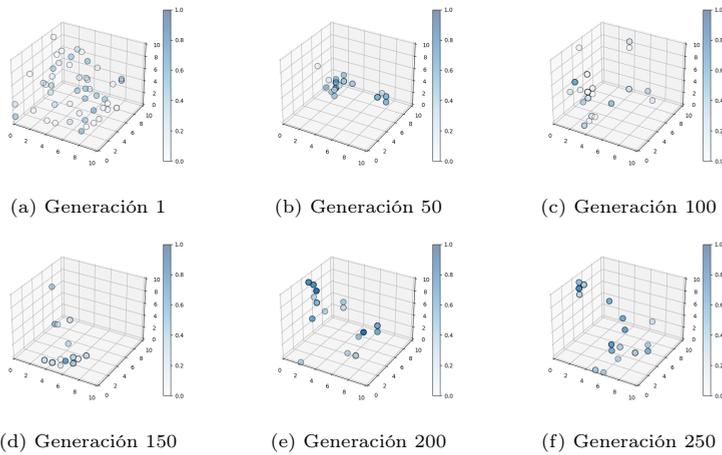


Figura 4.13: Posición de cada uno de los individuos para una corrida del algoritmo genético en diferentes etapas del proceso (Condición comida 2.0). El espacio de solución está representado por un SOM cúbico, cada punto representa la neurona ganadora correspondiente al individuo que se presentó como entrada al SOM, la intensidad del color azul de cada punto representa el nivel de emisión de luz azul dentro de la región de interés durante el proceso evolutivo, y, normalizado entre 0 y 1.

Emisión dentro de la región de interés, de la última generación, de una corrida del algoritmo evolutivo

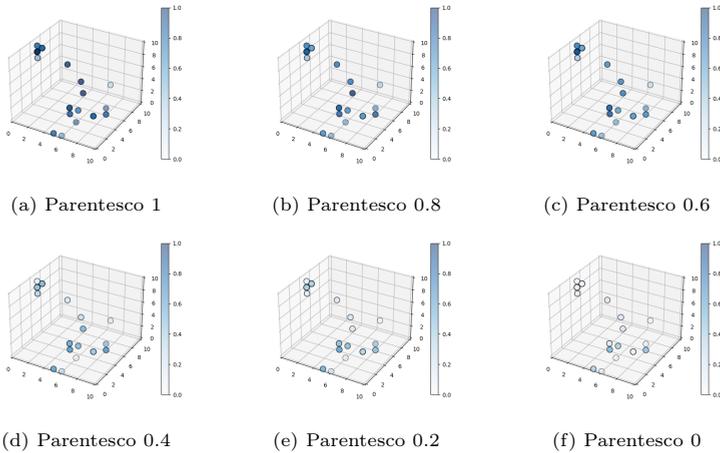


Figura 4.14: Emisión de luz dentro de la región de interés para la última generación (50 individuos) de una corrida del algoritmo evolutivo, para la condición comida 2.0, bajo cada una de las condiciones de parentesco, el color de los círculos representa la emisión de luz azul de cada uno de los individuos dentro de la región de interés para cada una de estas condiciones experimentales.

Nuestra hipótesis es que la eficacia de una estrategia depende en gran medida de las estrategias del resto de los miembros de la población. En particular, se consideran estrategias relacionadas con la emisión de luz en un contexto social. Por ejemplo, una estrategia consistente en no emitir luz nunca o raramente puede resultar óptima si hay un número suficiente de individuos en esa población que emiten luz indiscriminadamente, pero esa misma estrategia se volvería contraproducente si eso no ocurre y al mismo tiempo hay un número significativo de individuos que adoptan la conducta de emitir luz solo entre ellos.

En ese caso, la estrategia de no emitir luz perjudicaría al individuo que la sigue, ya que no estaría aprovechando las oportunidades de interacción social que se presentan. Por lo tanto, la eficacia de una estrategia depende de las estrategias de los demás individuos en la población y de la dinámica de interacción social que se establece entre ellos.

En este contexto, la evolución es un proceso dinámico que depende de las presiones de selección que actúan sobre los individuos de cada generación. Estas presiones pueden variar según las estrategias que emplean los individuos para adaptarse al entorno. La variación en la emisión de luz azul entre individuos de una misma generación y el cambio de las estrategias en las poblaciones a lo largo del tiempo influyen en el dinamismo de las poblaciones en el espacio de solución.

Este fenómeno es análogo al que se ha encontrado en procesos de co-evolución de conductas presa/depredador (Nolfi, 2012; Nolfi y Floreano, 1998), o cuando existe competencia entre diversas soluciones (Sims, 1994), dando lugar a lo que Nolfi (2012) denomina procesos evolutivos “open-ended”. Esto significa que si hay dos soluciones posibles para un problema, y una es ligeramente mejor que la otra, los individuos que usan la solución más efectiva tendrán más éxito reproductivo y transmitirán más genes a la siguiente generación. Pero si la solución más efectiva se vuelve muy común, esto puede alterar la dinámica de la competencia y hacer que la solución menos efectiva sea más ventajosa. Así, la evolución se adapta constantemente a los cambios en el entorno y en las soluciones empleadas por los individuos, lo que permite que la evolución siga de manera “open-ended” y no se estanque en un punto específico. Esto se refleja también en la Fig. 4.14, donde se aprecian diferentes tipos de conductas dentro de una misma población e incluso dentro de un mismo individuo, dependiendo del parentesco que percibe con el resto de los individuos del grupo.

4.2. Experimento 1.1: Evolución con parentesco invertido

Después de analizar los resultados expuestos anteriormente, surgió la siguiente pregunta: ¿es posible que la conducta de emitir luz azul y el nivel de parentesco que se observa en dicha conducta de los robots se deban no al proceso evolutivo y la selección por parentesco, sino a la propia arquitectura y dinámica de la red neuronal?

Para descartar esta hipótesis, realizamos un nuevo experimento en el que evolucionamos una población de robots, normalizando el parentesco de manera inversa a como lo hicimos anteriormente. Esto nos permitió evaluar si la conducta de emitir luz azul y el nivel de parentesco que se observa en dicha conducta son el resultado de la selección por parentesco o de la arquitectura y dinámica de la red neuronal.

Este experimento es importante porque nos permite determinar si la selección por parentesco es un factor clave en la evolución de la conducta de emitir luz azul en los robots o si esta conducta es simplemente un efecto de la arquitectura y dinámica de la red neuronal. En el primer caso, esperaríamos que la conducta de emitir luz azul y el nivel de parentesco que se observa en dicha conducta se mantengan, mientras que en el segundo caso esperaríamos que la conducta de emitir luz azul y el nivel de parentesco que se observa en dicha conducta desaparezcán.

Mientras que en los experimentos originales normalizamos el parentesco de 0 a 1 siendo 0 el valor que representaba la máxima diferencia entre los robots y 1 que los robots eran idénticos, ahora normalizaremos de 1 a 0, siendo 1 el valor de parentesco de robots totalmente distintos y 0 cuando se traten de robots genéticamente idénticos.

4.2.1. Entorno y robots

Siguiendo la metodología de los experimentos anteriores, los robots contaron con una cámara de 360 grados, dos ruedas con motores diferenciales, una cámara orientada hacia el piso capaz de detectar la presencia de la región de interés bajo el robot, mientras que un anillo de luces led permitía a los robots emitir luz azul.

4.2.2. Red neuronal

Cada uno de los robots estaba controlado por una red neuronal artificial con una capa de entrada de 8 neuronas y una capa de salida de 3 neuronas

(**figura 4.2**). La red neuronal se entrenó utilizando una función de pérdida de entropía cruzada y se optimizó utilizando el algoritmo de descenso de gradiente estocástico. Cada neurona de la red tenía una función de activación sigmoide $(\frac{1}{1+e^{-x}} - 0.5) * 2$, donde x es la sumatoria de la salida de las neuronas de la capa anterior multiplicada por el peso de su conexión a esa neurona, y devolvía valores entre -1 y 1 .

Capa de entrada

La capa de entrada de la red neuronal estaba compuesta por 8 neuronas. Las primeras 6 neuronas percibían cada una la presencia de luz azul, mientras que la séptima neurona recibía el valor de la cámara de piso. Este valor era de 1 cuando el robot se encontraba sobre una región con comida y 0 cuando no. La última neurona de la capa de entrada recibía el parentesco que dicho robot mantenía con el otro robot presente en el entorno. Como se ha mencionado anteriormente, esta variable estaba normalizada de forma inversa a la utilizada en el experimento 1.

Capa de salida

Al igual que en el experimento 1, la capa de salida estaba conformada por 3 neuronas. Las primeras 2 neuronas controlaban los motores del robot, cuyo valor de salida se normalizó de -15 a 15 para obtener la velocidad de los mismos. Al igual que en el experimento 1, estas salidas tomaban un valor igual a 0 cuando el robot se encontraba sobre la región de interés. Por último, la tercera neurona controlaba la emisión de luz azul, donde un valor de salida mayor a 0 encendía el anillo de LEDs y un valor menor a 0 lo apagaba.

4.2.3. Escenario

El experimento se realizó en un entorno simulado de 2 m^2 , con una región de interés de 30 cm de diámetro en el centro del mismo. En cada simulación, se situó un robot dentro de la región de interés, orientado hacia el centro, y otro robot en una posición y orientación aleatorias (**ver figura 4.3**).

4.2.4. Variables durante el proceso de evolución

Como ya se ha mencionado anteriormente, el objetivo de este experimento era descartar que los resultados obtenidos se debieran a un artefacto

Condiciones de evolución	
Cantidad de comida	2
Número de generaciones	250
Número de individuos por generación	50
Porcentaje de mutación	1.8 %
Cantidad de procesos evolutivos	4

Cuadro 4.11: Condiciones de evolución parentesco invertido

de la red neuronal. Por esta razón, se utilizaron los mismos parámetros de evolución que en el experimento 1 (sección 4.1.2). Al igual que en pruebas previas, el algoritmo evolutivo se ejecutó 4 veces. Dado que se consideró innecesario repetir todos los experimentos anteriores, solo se evolucionaron los individuos en el entorno con 2.0 unidades de comida.

Cantidad de comida y ciclos de vida Al igual que en el experimento 1, las simulaciones tuvieron una duración de 1200 ciclos de 0.5 milisegundos. Sin embargo, debido a que solo queríamos descartar que la evolución de la conducta altruista fuera un artefacto debido a la forma en que normalizamos el parentesco, solo evolucionamos a los robots bajo una condición de comida de 2.0 unidades.

Función de aptitud La función de aptitud fue exactamente la misma que en el experimento 1 (**ver formula 4.2**):

$$Aptitud\ Total = \sum_{i=0}^n (A_i = \begin{cases} (\frac{P_i * C}{R_i}) & \text{si } A_i < 1 \\ 1 & \text{en otro caso} \end{cases}) \quad (4.2)$$

Selección y cruza Siguiendo el mismo procedimiento que en el experimento 1 y por las mismas justificaciones, se aplicó una selección elitista del 50 % de la población, para el cruce se conformaron 50 parejas diferentes de manera aleatoria y se emplearon para generar 2 descendientes cada una para así mantener la población invariable durante todo el algoritmo evolutivo.

Mutación Al igual que en el experimento 1 se utilizó una mutación del 1.8 %.

Condiciones de la prueba								
Parentesco invertido	0	0.2	0.4	0.6	0.8	1	Costo	
Beneficio	1	1	0.8	0.6	0.4	0.2	0	0
$rb - c =$								

Cuadro 4.12: En este cuadro se puede ver como cambia el resultado de aplicar en cada una de las 6 condiciones de prueba, nótese que en este caso normalización del parentesco percibido está invertido, pero para el cálculo de la regla de Hamilton se usa su valor de forma normal

4.2.5. Prueba de altruismo con parentesco invertido

Para llevar a cabo estas pruebas utilizamos un diseño experimental con 6 condiciones idéntico a las pruebas hechas para el grupo comida 2.0 en las pruebas de altruismo previas, el grupo está compuesto por la última de las generaciones de cada algoritmo evolutivo (4 generaciones de 50 individuos), para un total de 200 individuos.

El grupo fue evaluado en las mismas condiciones en las que evolucionó, es decir, que la región de interés alberga 2 unidades de alimento, y el grupo fue evaluado bajo seis niveles de “falso parentesco”(ver **tabla 4.12**).

Para generar este falso parentesco, modificamos los valores de parentesco que la red neuronal de los robots recibe durante la simulación, independientemente del valor real que pueda tener. Este parentesco falso varía en cada condición con valores que van del 0 al 1 (ver **Tabla 4.12**) en incrementos de 0.2 para cada prueba, lo que nos proporciona seis valores diferentes de falso parentesco.

Al igual que en el proceso evolutivo, durante esta prueba, todos los robots desempeñarán tanto el papel de señalizador como el de forrajero con todos los robots pertenecientes a su misma generación, lo que suma un total de 98 simulaciones por individuo. La característica principal que deseamos cuantificar es el nivel de emisión de luz azul cuando el robot se encuentra dentro de la región de interés.

4.2.6. Resultados de la prueba de altruismo

Al igual que en las pruebas anteriores, nuestro interés se centra en analizar el comportamiento de los robots que exhiben conducta altruista. Por lo tanto, para fines del análisis estadístico, solo consideramos el 20% de los individuos con la mayor emisión de luz azul a lo largo de las 6 condiciones. Para este análisis, empleamos una prueba ANOVA de medidas repetidas de

una vía.

En el grupo evolucionado con parentesco invertido y 2 unidades de comida, se muestra que en las condiciones en las que existe un mayor parecido genético entre los robots (menor parentesco invertido), se logra una mayor emisión de luz azul (consulte la tabla 4.12) Así mismo, el ANOVA de medidas repetidas reveló un efecto de significativo del parentesco en la emisión de luz azul dentro de la región de interés, con ajuste de Greenhouse-Geisser $F(1.7, 66) = 7.6, p < 0.05$.

Como podemos ver al hacer comparaciones múltiples utilizando una prueba t de una sola vía, existen diferencias significativas entre la mayoría de las condiciones (ver tabla 4.13), con excepción de las comparaciones entre condiciones cercanas y con bajo parecido genético entre los robots (Parentesco invertido 1 y 0.8, 1 y 0.6, y 0.8 y 0.6). Esta significancia desaparece, similar a lo que ocurre con algunas condiciones del experimento realizado sin invertir el parentesco.

Estos resultados confirman que la capacidad de percibir la existencia de una relación de parentesco es lo que provoca en el experimento 1 la conducta de emitir luz azul en relación con este, y no un artefacto de la red provocado por la forma en que la información fue normalizada. Como consecuencia de esto, consideramos innecesario repetir el proceso evolutivo de todas las condiciones del experimento 1 en el experimento de parentesco invertido.

Parentesco invertido	0	0.2	0.4	0.6	0.8
0.2	**				
0.4	***	**			
0.6	***	**	**		
0.8	***	**	**	NS	
1	***	**	**	NS	NS

Cuadro 4.13: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía, Grupo *comida 2.0*, ** $p \leq 0.05$, *** $p \leq 0.01$

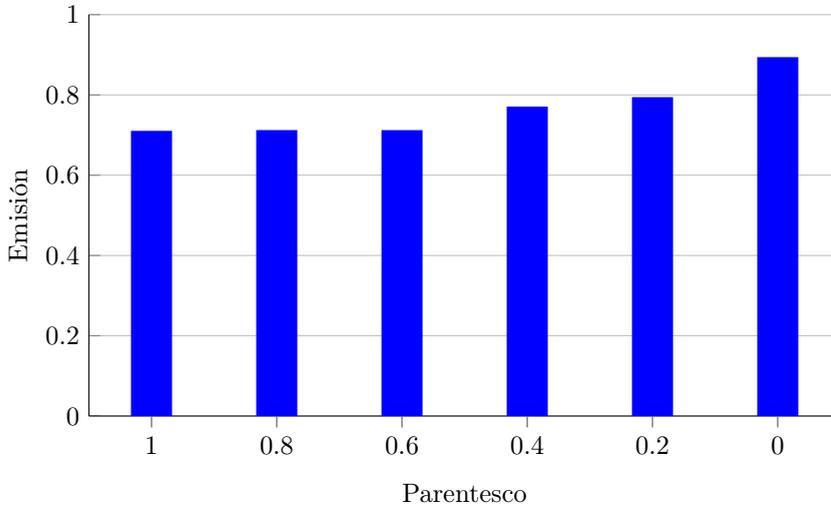


Figura 4.15: Promedio de emisión de luz según el parentesco percibido en la población evolucionada con parentesco invertido, a menor el número mayor el parentesco entre los individuos.

4.3. Experimento 2 y 2.1, percibiendo solo el color del otro robot, red con una capa oculta

4.3.1. Experimento de selección por similitud fenotípica

Una vez que se comprobó la posibilidad de evolucionar conductas altruistas en poblaciones heterogéneas de robots modelando la selección por parentesco, deseábamos evaluar la capacidad de los robots para inferir el parentesco usando su similitud fenotípica con otros robots, sin una señal explícita de dicha similitud.

Para ello, se emplearon dos tipos de redes neuronales diferentes para controlar el comportamiento de los robots en un entorno donde podían cooperar o no con otro robot. La primera red neuronal solo podía detectar el color del otro robot, mientras que la segunda podía detectar el color de ambos robots. Según la teoría de la selección por parentesco (Hamilton, 1963) y la teoría del gen de la barba verde (Dawkins, 1976), estas redes deberían favorecer la emergencia de conductas altruistas entre robots con colores similares.

Los resultados del experimento mostraron que, efectivamente, los robots con redes neuronales que podían detectar la similitud fenotípica con otros robots exhibieron una mayor conducta altruista en comparación con los robots con redes neuronales que solo podían detectar el color del otro robot. Las métricas utilizadas para evaluar la conducta altruista incluyeron la cantidad de comida recolectada y la cantidad de veces que los robots cooperaron entre sí.

Debido a que los robots debían ser capaces de percibir el color del otro robot presente en el entorno, se varió la estructura de la red neuronal que controla a los robots. Puesto que la tarea requería más entradas en dicha red y se supone más compleja que las realizadas anteriormente, se utilizó una red que cuenta con más nodos y capas (figura 4.16) que la utilizada en nuestros experimentos previos.

4.3.2. Entorno y robots del experimento 2

Los mismos robots simulados utilizados en el experimento 1 se emplearon también en el experimento 2, con las mismas características y componentes: una cámara de 360 grados, dos ruedas con motores diferenciales, una cámara orientada hacia el piso que podía detectar la región de interés y un anillo

de luces LED que les permitía emitir luz azul. El control de los robots se realizó mediante una red neuronal artificial.

Red neuronal

En este segundo experimento se optó por una red neuronal *feedforward fully connected* de 3 capas, la cual contaba con una capa de entrada, una capa oculta y una capa de salida. Todas las neuronas de la red usaron una función de activación sigmoide $\left(\frac{1}{1+e^{-x}} - 0.5\right) * 2$, donde x es la sumatoria de la salida de las neuronas de la capa anterior multiplicada por el peso de su conexión a esa neurona. Esta función devuelve valores entre -1 y 1.

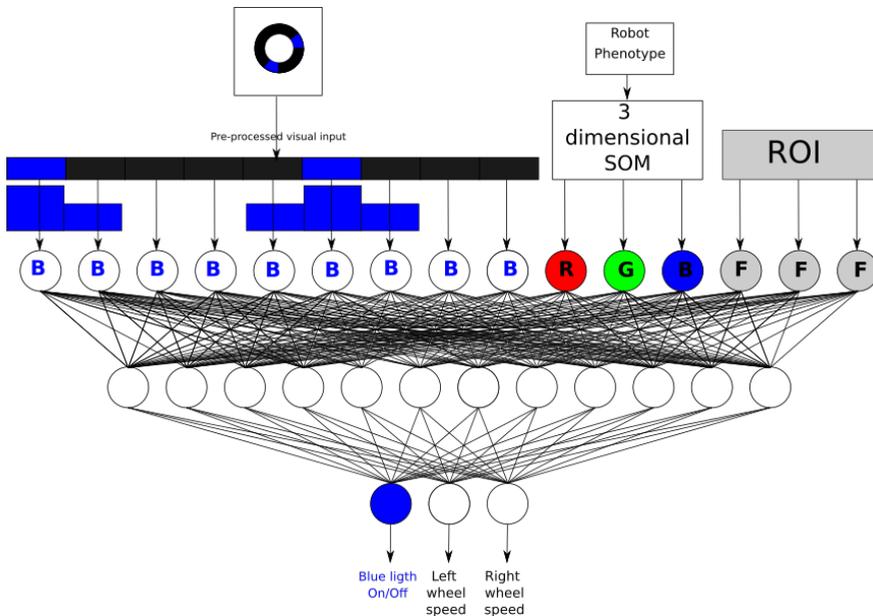


Figura 4.16: Red Neuronal para el experimento 2

Para comprobar si bajo estas condiciones surgían comportamientos altruistas, durante el proceso evolutivo utilizamos la misma tarea que en los experimentos previos, en los cuales uno de los robots se encontraba sobre la región de interés, la cual contenía comida, y dicho robot podía o no informar al otro robot de su posición por medio de la emisión de luz azul (ver Figura 4.17). No obstante, a diferencia de los experimentos anteriores, en los que

informábamos directamente a la red el parentesco que un robot mantenía con el otro robot en el entorno, para estas pruebas mapeamos el fenotipo del robot a un color específico, el cual podría ser percibido por el otro robot que comparte el entorno.

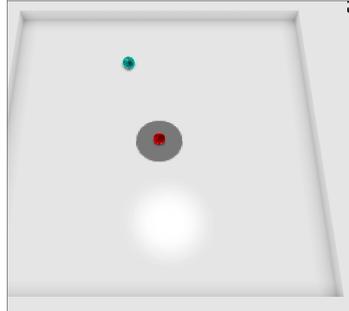


Figura 4.17: Ambiente en donde se llevaron a cabo las simulaciones, en gris la región de interés, el color asignado a los robots estará dado por el **SOM** y será percibido por los robots presentes en el entorno

Capa de entrada La capa de entrada estaba formada por 15 neuronas, de las cuales 9 detectaban la presencia de luz azul. Para ello, se procesó la imagen captada por la cámara de 360 grados y se dividió en 9 segmentos, cada uno de los cuales abarcaba 40 grados de la imagen. Si alguno de estos segmentos contenía luz azul, la neurona correspondiente aumentaba su activación en 1, mientras que sus dos neuronas adyacentes más cercanas aumentaban su activación en 0,6. Las 3 neuronas siguientes de la capa de entrada recibían los valores de color del otro robot presente en el escenario. Este valor se determinó mediante un mapa autoorganizado, cuya estructura y entrenamiento se explican en la sección 3.2. Las tres últimas neuronas recibían el valor asociado a la cantidad de comida presente en la región de interés.

Capa oculta Esta capa constaba de 12 neuronas, cada una de ellas conectada a todas las neuronas de la capa de entrada y la capa de salida.

Capa de salida Esta capa conservó la misma configuración que en experimentos anteriores, siendo las dos primeras neuronas las responsables de definir la velocidad de los motores del robot, la cual se obtuvo multiplicando

la salida de dichas neuronas por 15, para lograr un intervalo de velocidad de -15 a 15 en cada motor. La neurona restante tenía la tarea de establecer si el anillo de leds se activaba o se desactivaba; valores de salida inferiores a cero desactivaban el anillo de leds, mientras que valores superiores a cero lo activaban.

Escenario

Al igual que en los experimentos 1 y 1.1, el entorno simulado tenía un tamaño de 2 m^2 . Tenía una región de interés delimitada por un círculo gris con un diámetro de 30 cm situado en el centro del entorno, que representaba una fuente de alimento. La aptitud del robot estaba directamente relacionada con el tiempo que pasaba en esa región.

Asignación de color

Se asignaron colores a cada uno de los robots que pertenecen a una generación previamente a las simulaciones de dichos robots. Para ello se utilizó un SOM entrenado como se describe en la **sección 3.2**, el cual representa el espacio de solución de todos los valores de pesos posibles para esta red neuronal. Se puede explicar cómo se asigna el color en los siguientes pasos:

1. **Usar el fenotipo de un robot como entrada:** En este paso, el SOM recibe como vector de entrada el fenotipo correspondiente al robot al que se desea asignar un color, es decir, el vector de pesos de su red neuronal.
2. **Buscar el nodo ganador:** Se midió la distancia euclidiana entre el vector de entrada y cada uno de los nodos del SOM, determinando así un nodo ganador (aquel con menor distancia euclidiana al vector de entrada).
3. **Regresar las coordenadas del nodo ganador:** Una vez determinado el nodo ganador del SOM, se utilizaron los valores correspondientes a las coordenadas que dicho nodo ocupa en el espacio del SOM para asignar un color.
4. **Asignar un color:** Cada una de las tres coordenadas del nodo ganador se convirtió a su equivalente en el espacio de color RGB, de manera que las tres coordenadas en conjunto formaran un color, como se muestra en la **figura 4.18**.

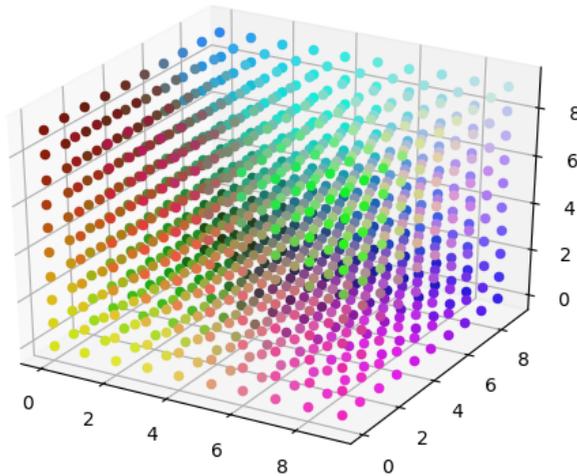


Figura 4.18: Representación gráfica del color asignado al robot según el nodo ganador del som correspondiente a su fenotipo.

5. **Normalizar la entrada:** Para alimentar nuestra red, los tres valores RGB correspondientes a cada robot se normalizaron de 0 a 1.
6. **Repetir para cada robot:** Este proceso se iteró hasta asignar un color a todos los robots pertenecientes a la generación en turno.

4.3.3. Variables durante el proceso de evolución experimento 2

La disponibilidad de alimento en la región de interés durante cada prueba de los robots se modificaba según la condición (ver tabla 4.14). En la condición de abundancia de alimento (experimento 2), la cantidad de alimento en la región de interés fue de 2 unidades, mientras que en la condición de alimento medio (experimento 2.1), la cantidad de alimento en la región de interés osciló de forma aleatoria entre 1 y 2 en cada una de las simula-

ciones de cada robot. Cada una de las simulaciones tuvo una duración de 1200 ciclos de vida.

Condiciones de evolución		
Cantidad de alimento para cada condición	Abundancia 2	Promedio 1-2
Número de procesos evolutivos	4	
Individuos por generación	100	
Porcentaje de mutación	1.8 %	
Número de generaciones	1000	

Cuadro 4.14: Condiciones de evolución para cada condición de evolución modelando barba verde.

Función de aptitud Se utilizó la misma función de aptitud que en los experimentos previos (**ver formula 4.3**):

$$Aptitud\ Total = \sum_{i=0}^n (A_i = \begin{cases} (\frac{P_i * C}{R_i}) & \text{si } A_i < 1 \\ 1 & \text{en otro caso} \end{cases}) \quad (4.3)$$

Selección y cruza Siguiendo el mismo procedimiento que en el experimento 1 y por las mismas razones, se aplicó un criterio de selección elitista y, para evitar el problema de una convergencia prematura asociado a este tipo de selección, se redujo la presión selectiva utilizando un porcentaje del 50 % de la población. Asimismo, con el proceso de cruza se formaron parejas de forma aleatoria equivalentes al 50 % de la población, donde cada individuo seleccionado era parte de 2 parejas distintas, generando cada una de ellas 2 descendientes para mantener el tamaño de la población.

Mutación Al igual que en el experimento 1, los individuos pertenecientes a una nueva generación tuvieron una probabilidad de mutación del 1.8 %, es decir, cada uno de los bits que componían su genotipo tenía una probabilidad del 1.8 % de cambiar de cero a uno y viceversa.

Duración del algoritmo y condición de paro El proceso evolutivo se utilizó para evolucionar los pesos de las conexiones de la red neuronal (**ver figura 4.16**). Cada uno de los procesos evolutivos contó con poblaciones de 100 individuos. Dado que la red neuronal utilizada era más compleja que

la utilizada en el experimento 1 y la tarea de reconocer el parentesco del otro robot mediante su color en lugar de ser dado numéricamente también era más compleja, optamos por incrementar el número de generaciones para la condición de paro. En este experimento, incrementamos el número de generaciones a 1000.

En todas las condiciones, como en los anteriores experimentos, todos los robots desempeñaron el papel de señalizador y de forrajero con todos los demás robots de su misma generación, para un total de 188 simulaciones por robot, 99 como señalizador y 99 en el papel de forrajero. Al igual que en los experimentos previos, se evolucionaron 4 poblaciones por condición para mitigar los efectos del azar.

4.3.4. Pruebas para determinar si la emisión de luz es una señal confiable de comida en el experimento 2

Como mencionamos en la sección 4.1.3, nuestra definición de altruismo depende de que los robots consideren la emisión de luz azul como una señal confiable de comida. Por lo tanto, al igual que en experimentos previos, debimos determinar si los robots eran capaces de encontrar la región de interés de forma eficaz cuando el robot señalizador emitía luz azul.

Para verificar la confiabilidad de la señal, tomamos a los robots pertenecientes a la última generación de cada una de las 4 poblaciones evolucionadas para cada una de las 2 condiciones evolutivas, utilizando la misma tarea de forrajero realizada durante su evolución (ver figura 4.17), bajo dos condiciones: la primera llamada "luz encendida", donde el robot señalizador siempre emitía luz azul, y otra condición llamada "a ciegas", en la que el robot señalizador siempre mantenía su anillo de leds apagado.

Condición con luz encendida

Los robots de la última generación de cada una de nuestras poblaciones tuvieron la misma tarea, utilizando los mismos parámetros y escenario que durante su evolución. La única diferencia fue que el robot que actuaba como señalizador siempre tenía encendido el anillo de LED azules, independientemente de la salida de su red neuronal.

Al igual que durante el proceso evolutivo, cada robot actuó como señalizador con todos los demás robots de su población, 99 veces como señalizador y 99 veces como forrajero. Es importante destacar que lo que nos interesa

medir en esta condición es el tiempo que los robots pasan en la región de interés cuando actúan como forrajeros.

Condición a ciegas

Esta condición se utilizó como referencia para determinar si las poblaciones de robots previamente evolucionadas utilizaban realmente la luz azul para encontrar la región de interés. Para ello, se utilizó el mismo escenario, parámetros y procedimientos empleados durante la condición con la luz encendida. La única diferencia es que el anillo de LED azules de los robots que actuaban como señalizadores se apagó durante todas las simulaciones. Al igual que en la prueba anterior, solo nos interesaba medir el tiempo que el robot forrajeador pasaba dentro de la región de interés.

Como se puede observar en los gráficos, hay diferencias significativas entre el tiempo que pasan los forrajeadores en la región de interés cuando la luz del otro robot estaba siempre encendida, en comparación con el tiempo que pasaban cuando estaba apagada.

Resultados de las condiciones con luz encendida y a ciegas

Para cada una de las poblaciones que realizaron ambas tareas, se llevó a cabo una prueba t de medidas repetidas para comparar el número de ciclos normalizados que los robots pasaron dentro de la región de interés al desempeñar el papel de forrajeador en las condiciones de "a ciegas" frente a "luz encendida".

En la condición de abundancia de comida, se encontraron diferencias significativas entre el número de ciclos que los robots permanecieron en la región de interés en la condición con la luz encendida ($M = 0.7047$, $SD = 0.1632$) y la cantidad de ciclos que permanecieron en la región de interés en la condición a ciegas ($M = 0.04413$, $SD = 0.0281$); $p < 0.01$.

En la condición de comida variable, también se encontraron diferencias significativas entre el número de ciclos que los robots permanecieron dentro de la región de interés en la condición con la luz encendida ($M = 0.3696$, $SD = 0.2713$) y el número de ciclos que permanecieron en la región de interés en la condición a ciegas ($M = 0.0607$, $SD = 0.04209$); $p < 0.01$.

En la condición de comida variable, también se encontraron diferencias significativas entre el número de ciclos que los robots permanecieron dentro de la región de interés en la condición con la luz encendida ($M = 0.3696$, $SD = 0.2713$) y el número de ciclos que permanecieron en

la región de interés en la condición a ciegas ($M = 0.0607, SD = 0.04209$); $p < 0.01$.

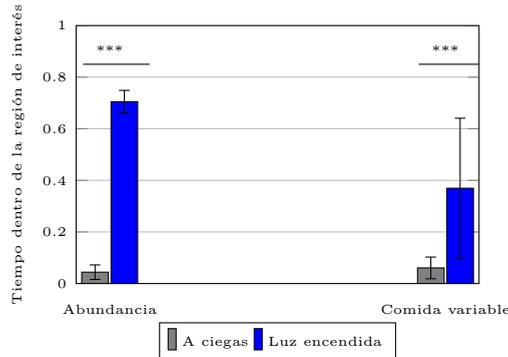


Figura 4.19: Diferencias entre las condiciones “luz encendida” y “a ciegas”, para los robots que solo perciben el color del otro robot, una prueba t de medidas repetidas fue realizada para ver las diferencias entre el número de ciclos que los robots pasan dentro de la región de interés para cada condición, los bigotes de la gráfica muestran la desviación estándar, *** $p < 0.01$.

4.3.5. Pruebas para determinar el nivel de altruismo

Una vez establecido que la emisión de luz se interpreta como una señal de alimento en ambas condiciones evolutivas, nos interesaba determinar si los robots evolucionados, tanto en la condición de abundancia como en la de comida variable, desarrollaron el comportamiento de señalización de alimento. Además, queríamos determinar si, como sugiere la regla de Hamilton, este comportamiento está relacionado con el nivel de parentesco.

Para evaluar el nivel de altruismo en los robots evolucionados, se llevaron a cabo dos experimentos: uno en la condición de abundancia y otro en la condición de comida variable. En la condición de abundancia, se utilizó un diseño experimental de 1×6 , con 6 niveles de parentesco y 2 unidades de comida en la región de interés, como se muestra en la Tabla 4.15. En la condición de comida variable, se utilizó un diseño de 6×6 , con 6 niveles de parentesco y 6 valores diferentes de comida, como se muestra en la Tabla 4.16.

En cada una de estas condiciones experimentales, se seleccionaron las poblaciones de la última generación de cada algoritmo evolutivo, lo que resultó en 4 poblaciones de 100 individuos por condición, para un total de 400

Pruebas de altruismo, condición de abundancia						
Parentesco con el otro robot	1	0.8	0.6	0.4	0.2	0
Cantidad de comida	2					

Cuadro 4.15: Condiciones de prueba para determinar nivel de altruismo en la condición de abundancia

Pruebas de altruismo, condición comida variable						
Parentesco con el otro robot	1	0.8	0.6	0.4	0.2	0
Cantidad de comida	2					
	1.8					
	1.6					
	1.4					
	1.2					
	1					
Generaciones por grupo	4					
Individuos por generación	100					
Individuos por condición	400					

Cuadro 4.16: Condiciones de prueba para determinar nivel de altruismo experimento 2 en la condición comida variable

individuos por grupo. Cada robot de cada uno de estos grupos desempeñó el papel de señalizador 20 veces para cada una de las condiciones experimentales. La tarea, el entorno y los parámetros utilizados fueron los mismos que durante el proceso evolutivo.

La Tabla 4.15 muestra las condiciones experimentales para determinar el nivel de altruismo en la condición de abundancia, mientras que la Tabla 4.16 muestra las condiciones experimentales para determinar el nivel de altruismo en la condición de comida variable.

Manipulación del parentesco. Para manipular el parentesco del otro robot presente en el entorno, generamos nuevos robots tomando el fenotipo del individuo que realizaría la prueba y mutando el porcentaje correspondiente de esa condición. Utilizamos un 0% para un parentesco de 1, un 20% para un parentesco de 0,8, un 40% para conseguir un parentesco de 0,6, y así sucesivamente. Generamos un nuevo robot utilizando este método para cada una de las 20 simulaciones que cada robot realizó para cada condición

experimental.

Estos “nuevos robots” desempeñaron el papel de forrajeadores, mientras que el individuo medido desempeñó el papel de señalizador. Es importante señalar que estos “nuevos robots” sólo sirvieron para medir el comportamiento de la población ya evolucionada. Por lo tanto, no nos interesa medir el rendimiento de estos robots. La razón por la que creamos nuevos robots en lugar de simplemente alimentar la red con un falso parentesco, como en experimentos anteriores (véase la sección 4.1.6), es que queríamos que el comportamiento de los robots creados se correspondiera con su fenotipo, descartando así cualquier tipo de variable de confusión en esta prueba.

La característica principal que queremos cuantificar en estas pruebas es el nivel de emisión de luz azul cuando el robot señalizador está dentro de la región de interés y el robot forrajeador está fuera de ella.

4.3.6. Resultados de la condición de abundancia (Experimento 2.1)

Para los robots evolucionados en condiciones de abundancia, las medias de emisión fueron las siguientes (Fig. 4.20): los robots en la condición de parentesco 1 tuvieron una emisión del 93.3876 % (SD=17.0109), en la condición de parentesco 0.8, los robots tuvieron una emisión del 88.0034 % (SD=17.3984), en la condición de parentesco 0.6, los robots tuvieron una emisión del 86.9459 % (SD=16.5320), en la condición de parentesco 0.4, los robots tuvieron una emisión del 83.789 % (SD=20.9111), en la condición de parentesco 0.2, los robots tuvieron una emisión del 84.3847 % (SD=20.0411), y en la condición de parentesco 0, los robots tuvieron una emisión del 84.1845 % (SD=19.3984).

Podemos observar que las poblaciones resultantes de estas condiciones evolutivas son altamente altruistas, como se esperaba a partir de los resultados del Experimento 1. La cantidad de comida disponible en el entorno 2.0 favorece la aparición de comportamientos altruistas y es estable durante todo el periodo evolutivo, lo que hace que la emisión de luz azul en la región de interés sea un comportamiento favorecido por el proceso evolutivo.

Sin embargo, es importante analizar si esta tendencia a una señalización ligeramente mayor en la condición de parentesco 1 es significativa en comparación con otras condiciones. Esto indicaría que, a pesar de tratarse de poblaciones altamente altruistas, no se trata de un comportamiento de altruismo ingenuo, sino de altruismo selectivo.

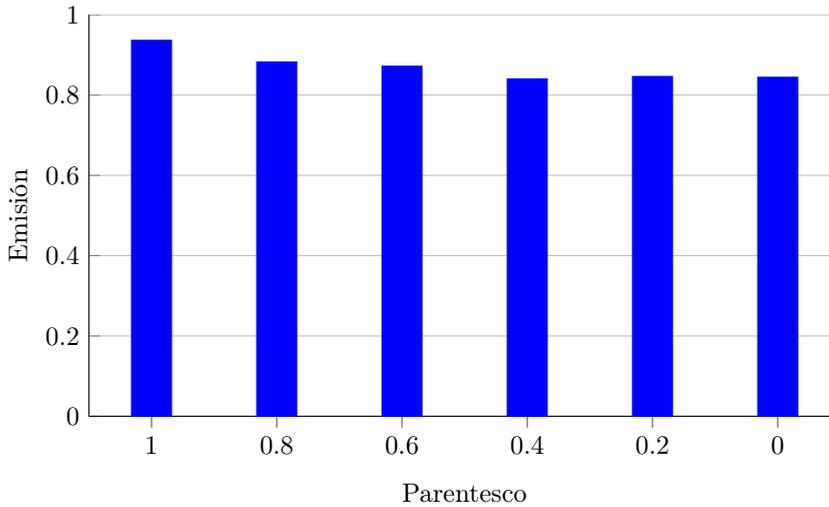


Figura 4.20: Promedio de emisión de luz según el parentesco percibido en la población evolucionada en la condición de abundancia, conociendo solo el parentesco del otro robot

Resultados estadísticos experimento 2.1 (Condición de abundancia)

Al igual que en los experimentos previos, en este caso solo estamos interesados en analizar el comportamiento de los robots que muestran una conducta altruista (emitir luz dentro de la región de interés) y si esta emisión se relaciona con el nivel de parentesco percibido por el robot. Para fines del análisis estadístico, utilizamos el 20% de individuos con mayor emisión en cada grupo a lo largo de las 6 condiciones de parentesco. Para dicho análisis, utilizamos una prueba ANOVA de medidas repetidas de una vía para el grupo conformado por la última generación de cada una de las cuatro ejecuciones del algoritmo evolutivo.

En el grupo evolucionado en la condición de abundancia (2 unidades de comida), el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con un valor de $F(5, 395) = 9.3$, $p = 2.0e - 08$ (ajuste de Greenhouse-Geisser).

Se utilizó una prueba T de múltiples comparaciones con una vía y una corrección de Bonferroni para comparar el grupo evolucionado con 2 unidades de comida bajo todas las condiciones de parentesco (véase tabla4.17). Se encontraron diferencias solo entre la condición de 1 de parentesco con

todas las condiciones con un parentesco menor o igual a 0.6 ($p < 0.05$), si bien la diferencia entre el grado de emisión de la condición con parentesco 1 y el resto de las condiciones es pequeña esta es estadísticamente significativa, y nos muestra que debe existir un mecanismo de discriminación por parentesco aun dentro del subconjunto de la población más altruista, que permite que esta conducta domine el acervo genético, esto es importante porque nos demuestra que con solo conocer indirectamente el genotipo del otro robot presente en la arena y si bien la emisión no se ajusta a la regla de Hamilton si nos habla de que dadas las condiciones ideales es posible el surgimiento de un mecanismo parecido al de la barba verde y en condiciones de abundancia de comida este tiende a generar altos niveles de altruismo.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	0.68				
0.6	**	1			
0.4	***	0.071	0.051		
0.2	***	0.594	0.969	1	
0	***	0.280	0.190	1	1

Cuadro 4.17: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, para el experimento 2.1 (condición de abundancia), ** $p <= 0.05$, *** $p <= 0.01$

4.3.7. Resultados de la condición comida variable

Para los robots evolucionados en condición de abundancia, los promedios de emisión fueron los siguientes (**Fig.4.21**):

En la condición de comida 2, los robots con parentesco 1 tuvieron una emisión de 33.1873 % ($SD = 41.5611$), mientras que los robots con parentesco 0.8 tuvieron una emisión de 33.4486 % ($SD = 36.6402$), los robots con parentesco 0.6 tuvieron una emisión de 30.6474 % ($SD = 34.1219$), los robots con parentesco 0.4 tuvieron una emisión de 29.2302 % ($SD = 35.3076$), los robots con parentesco 0.2 tuvieron una emisión de 30.7941 % ($SD = 35.7125$), y los robots con parentesco 0 tuvieron una emisión de 29.8665 % ($SD = 34.7379$).

En la condición de comida 1.8, los robots con parentesco 1 tuvieron una emisión de 34.0781 % ($SD = 41.7704$), mientras que los robots con parentesco 0.8 tuvieron una emisión de 31.0446 % ($SD = 34.9103$), los robots con parentesco 0.6 tuvieron una emisión de 29.7020 % ($SD = 33.1264$), los robots con parentesco 0.4 tuvieron una emisión de 29.8279 % ($SD =$

Gráfica del 20% de individuos más emisores experimento 2.2

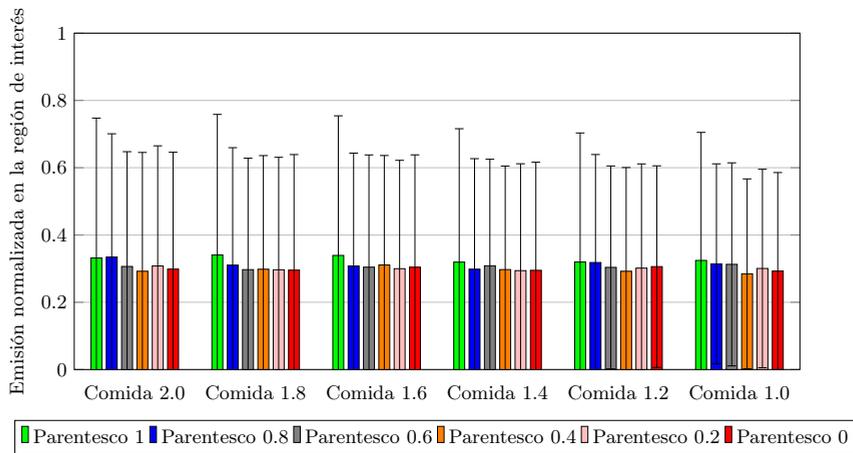


Figura 4.21: Promedio de emisión de luz según el parentesco percibido en la población evolucionada en la condición comida promedio, conociendo solo el parentesco del otro robot.

33.7762), los robots con parentesco 0.2 tuvieron una emisión de 29.6591 % ($SD = 33.4362$), y los robots con parentesco 0 tuvieron una emisión de 29.5653 % ($SD = 34.3422$).

En la condición de comida 1.6, los robots con parentesco 1 tuvieron una emisión de 33.9232 % ($SD = 41.5051$), mientras que los robots con parentesco 0.8 tuvieron una emisión de 30.7797 % ($SD = 33.5562$), los robots con parentesco 0.6 tuvieron una emisión de 30.4461 % ($SD = 33.3594$), los robots con parentesco 0.4 tuvieron una emisión de 31.0847 % ($SD = 32.5449$), los robots con parentesco 0.2 tuvieron una emisión de 29.9816 % ($SD = 32.2152$), y los robots con parentesco 0 tuvieron una emisión de 30.4457 % ($SD = 33.3757$).

Los robots en la condición comida 1.4 con parentesco 1 tuvieron una emisión de 31.9425 % ($SD = 39.6510$), mientras que los robots con parentesco 0.8 tuvieron una emisión de 29.84355 % ($SD = 32.8492$), los robots con parentesco 0.6 tuvieron una emisión de 30.8414 % ($SD = 31.6806$), los robots con parentesco 0.4 tuvieron una emisión de 29.72071 % ($SD = 30.7820$), los robots con parentesco 0.2 tuvieron una emisión de 29.4063 % ($SD = 31.7700$), los robots con parentesco 0 tuvieron una emisión de 29.4966 % ($SD = 32.1397$).

En la condición de comida 1.2, los robots con parentesco 1 tuvieron una emisión de 31.9747 % ($SD = 38.3573$), mientras que los robots con parentesco 0.8 tuvieron una emisión de 31.8151 % ($SD = 32.1046$), los robots con parentesco 0.6 tuvieron una emisión de 30.3735 % ($SD = 30.1556$), los robots con parentesco 0.4 tuvieron una emisión de 29.2255 % ($SD = 30.8313$), los robots con parentesco 0.2 tuvieron una emisión de 30.1555 % ($SD = 30.9786$), y los robots con parentesco 0 tuvieron una emisión de 30.6020 % ($SD = 29.9645$).

En la condición de comida 1 con parentesco 1 los robots tuvieron una emisión de 32.4329 % ($SD = 38.0621$), los robots con parentesco 0.8 tuvieron una emisión de 31.4187 % ($SD = 29.7319$), los robots con parentesco 0.6 los robots tuvieron una emisión de 31.2707 % ($SD = 30.1808$), los robots con parentesco 0.4 los robots tuvieron una emisión de 28.4634 % ($SD = 28.2170$), los robots con parentesco 0.2 tuvieron una emisión de 30.0454 % ($SD = 29.5007$), los robots con parentesco 0 tuvieron una emisión de 29.2842 % ($SD = 30.1369$).

En los resultados se observa una tendencia a aumentar significativamente la emisión de luz azul cuando la relación de parentesco entre los dos robots es igual a 1, en comparación con las condiciones de prueba. Sin embargo, esta diferencia es pequeña y no se mantiene para la condición de parentesco 1 alimento 2.0, lo que puede dificultar la interpretación de los resultados.

No obstante, como demuestran los bigotes de nuestros gráficos, hay individuos altamente altruistas en nuestras poblaciones. Esto nos lleva a preguntarnos si existe un subconjunto de nuestra población que muestre un comportamiento que se ajuste mejor a la regla de Hamilton, lo que podría estar favoreciendo la supervivencia de los individuos altamente altruistas y, a su vez, evitando la extinción del comportamiento de emitir luz azul, como se señala que sucede en el resto de la bibliografía sobre el tema.

Búsqueda de los individuos con comportamiento cercano a la regla de Hamilton

A causa de la ausencia de convergencia de nuestras poblaciones en un solo punto del espacio de solución, y la presencia de individuos en nuestras poblaciones que emiten sin restricción, mientras que otros no emiten bajo ninguna condición, resultaba complejo determinar las causas que provocaban la conducta de emitir luz en las poblaciones, a pesar de haber sido demostrado que esta es una señal fiable de la presencia de comida. En teoría, aquellos que presentan una conducta de altruismo ingenuo deberían extinguirse ante la presencia de individuos egoístas que logran llegar a la región de interés aprovechando su emisión de luz azul, ya que los primeros verían su aptitud reducida al permitir que los robots egoístas llegaran a la región de interés sin recibir posteriormente el mismo trato de parte de ellos. Esto nos inclinó a pensar que debería existir al menos un subconjunto de la población que evitó que la conducta egoísta floreciera lo suficiente para extinguir totalmente a los altruistas ingenuos, y que probablemente este subconjunto de la población sigue un comportamiento similar al predicho por la regla de Hamilton. Como ya se ha mencionado, la regla de Hamilton es una teoría muy importante que se ha utilizado para entender cómo surgen y se mantienen las conductas altruistas en los individuos.

Para encontrar a aquellos individuos cuyo comportamiento se aproximaba a la emisión idealizada, normalizamos la emisión de cada robot entre cero y uno. Esto se hizo para no descartar individuos que pudiesen tener una conducta de discriminación por parentesco, pero que sus rangos de emisión máxima y mínima estuvieran cercanos, o que dicha emisión fuera relativamente baja, permitiéndonos medir mejor el efecto de la discriminación por parentesco en la emisión de luz azul.

La emisión idealizada para cada una de las condiciones experimentales se calculó multiplicando el parentesco presente en cada una de las condiciones experimentales por la cantidad de comida presente en la región de interés y dividiendo dicho resultado entre dos. Así, asumimos que esta emisión

idealizada para cada una de las condiciones experimentales mostraría un incremento lineal. La fórmula utilizada para este cálculo se muestra en la ecuación 4.4.

Luego, restamos la emisión idealizada de esa condición a la emisión normalizada de dicho robot en la misma y obtenemos su distancia absoluta. Tomamos la distancia absoluta de cada uno de los 20 resultados que los robots obtuvieron en cada una de las respectivas 36 condiciones de prueba en relación con la emisión idealizada, y se procedió a la sumatoria de este valor para todas las condiciones. Como resultado, cuanto más alto fuera este valor, más alejada estaba la conducta de dicho individuo de la emisión ideal.

Para cada una de las generaciones puestas a prueba, seleccionamos a los 10 individuos cuyo comportamiento se aproximaba más a la emisión idealizada. En consecuencia, buscamos a aquellos individuos que, a lo largo de las 36 condiciones de prueba, presentaran una conducta similar a la establecida por la regla de Hamilton, es decir, un aumento de la emisión de luz en relación con la cantidad de comida presente en el entorno y el parentesco percibido. La totalidad de este procedimiento de normalización y ajuste se puede resumir en la ecuación 4.4.

$$AjusteEmisionIdealizada = \sum_{i=1}^{36} \left| \left(\frac{1}{E_{max} - E_{min}} \right) * (x_i - E_{min}) - \frac{C_i * P_i}{2} \right| \quad (4.4)$$

Donde el valor E_{max} es la emisión máxima que el robot tuvo en la región de interés durante las 36 condiciones de prueba, E_{min} es la emisión mínima que el robot presentó durante las 36 condiciones, x la emisión del robot en esa condición, C la cantidad de comida en esa condición, P el parentesco en esa condición, e i es el contador de cada una de las condiciones.

Resultados de la condición comida variable

Los promedios de emisión para los robots evolucionados en condición de abundancia fueron los siguientes: **Fig.4.22**:

Resultados estadísticos experimento 2.2

Para verificar si una parte de la población cumplía con la regla de Hamilton y explicaba la existencia de individuos con altruismo ingenuo, se empleó el 10% que más se ajustó a la norma de Hamilton en cada grupo a lo largo

Gráfica del 10% de individuos que más se ajustan a la regla de Hamilton experimento 2.2

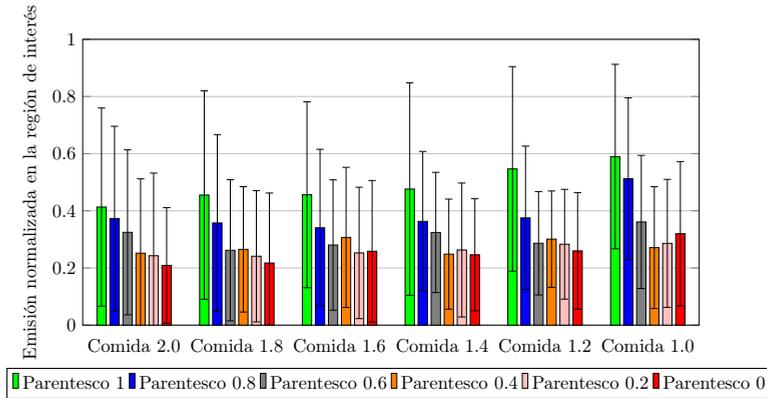


Figura 4.22: Promedio de emisión de luz según el parentesco percibido en la población evolucionada en la condición comida promedio, conociendo solo el parentesco del otro robot, con los valores normalizados, para el 10% de la población que más se ajusta a la regla de Hamilton.

de las seis condiciones de parentesco para la cantidad de comida 2.0. Para el análisis mencionado, se utilizó una prueba ANOVA de medidas repetidas de una vía para cada grupo.

En las pruebas con comida 2.0, el ANOVA de medidas repetidas reveló un efecto significativo del Parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 195) = 7.2$, $p < 0.05$. Es importante tener en cuenta que los valores F y p que se muestran son los correspondientes al efecto del Parentesco, y no al modelo completo. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Es importante tener en cuenta que los valores F y p que se muestran son los correspondientes al efecto del Parentesco, y no al modelo completo. Además, se ha aplicado una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo evolucionado con 2.0 unidades de comida (tabla 4.18), bajo todas las condiciones de parentesco, encontramos diferencias, existen diferencias significativas $p < 0.05$, cuando se compara la conducta de los robots ante robots con alto parentesco entre ellos y bajo

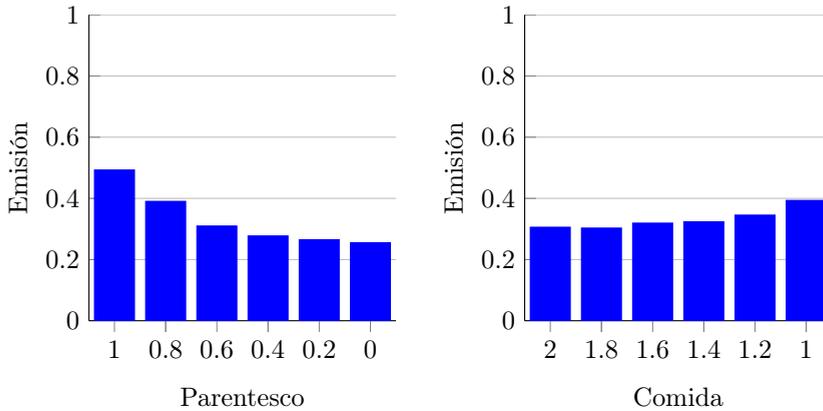


Figura 4.23: Promedio de emisión del 10% de los individuos que mejor se ajustan a la regla de Hamilton para las 4 ejecuciones del algoritmo evolutivo, agrupados según la cantidad de parentesco y la cantidad de comida en cada una de las 36 condiciones de prueba.

parentesco.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	1				
0.6	1	1			
0.4	0.065	0.124	1		
0.2	**	**	0.766	1	
0	***	***	**	1	1

Cuadro 4.18: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 2.0 , ** $p \leq 0.05$, *** $p \leq 0.01$

En las pruebas con comida 1.8 el ANOVA de medidas repetidas reveló un efecto significativo del Parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 195) = 7.7$, $p < 0.05$.

Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

La prueba *t* de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en las pruebas con 1.8 unidades de comida, nuevamente solo encontramos diferencias significativas $p < 0.05$ entre condiciones de alto parentesco y de bajo parentesco (**tabla 4.19**).

Parentesco	1	0.8	0.6	0.4	0.2
0.8	1				
0.6	**	0.123			
0.4	**	0.113	1		
0.2	***	0.094	1	1	
0	***	**	1	1	1

Cuadro 4.19: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.8 , ** $p \leq 0.05$, *** $p \leq 0.01$

En las pruebas con comida 1.6 el ANOVA de medidas repetidas reveló un efecto significativo del Parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 195) = 6.2$, $p < 0.05$.

Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

La prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en las pruebas con 1.6 unidades de comida, nuevamente solo encontramos diferencias significativas $p < 0.05$ entre condiciones de parentesco 1 el resto de ellas (**tabla 4.20**) .

Parentesco	1	0.8	0.6	0.4	0.2
0.8	1				
0.6	**	0.123			
0.4	**	0.113	1		
0.2	***	0.094	1	1	
0	***	**	1	1	1

Cuadro 4.20: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.6 , ** $p \leq 0.05$, *** $p \leq 0.01$

En las pruebas con comida 1.4 el ANOVA de medidas repetidas reveló un efecto significativo del Parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 195) = 5.7$, $p < 0.05$.

Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

La prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en las pruebas con 1.4 unidades de comida, nuevamente solo encontramos diferencias significativas $p < 0.05$ entre condiciones de parentesco 1 el resto de ellas (**tabla 4.21**) .

Parentesco	1	0.8	0.6	0.4	0.2
0.8	1				
0.6	0.531	1			
0.4	***	0.213	0.689		
0.2	**	0.800	1	1	
0	**	0.246	1	1	1

Cuadro 4.21: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 1.4 , ** $p \leq 0.05$, *** $p \leq 0.01$

En las pruebas con comida 1.2 el ANOVA de medidas repetidas reveló un efecto significativo del Parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 195) = 9$, $p < 0.05$.

Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

La prueba *t* de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en las pruebas con 1.2 unidades de comida, nuevamente solo encontramos diferencias significativas $p < 0.05$ entre condiciones de parentesco 1 el resto de ellas (**tabla 4.22**) .

Parentesco	1	0.8	0.6	0.4	0.2
0.8	0.402				
0.6	***	1			
0.4	***	1	1		
0.2	***	0.577	1	1	
0	***	0.220	1	1	1

Cuadro 4.22: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 1.2 , ** $p \leq 0.05$, *** $p \leq 0.01$

En las pruebas con comida 1.0 el ANOVA de medidas repetidas reveló un efecto significativo del Parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 195) = 11$, $p < 0.05$.

Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

La prueba *t* de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en las pruebas con 1.2 unidades de comida, nuevamente solo encontramos diferencias significativas $p < 0.05$ entre condiciones de parentesco 1 el resto de ellas (**table 4.23**) .

Parentesco	1	0.8	0.6	0.4	0.2
0.8	0.402				
0.6	***	0.114			
0.4	***	***	1		
0.2	***	***	1	1	
0	***	**	1	1	1

Cuadro 4.23: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida 1*, ** $p \leq 0.05$, *** $p \leq 0.01$

En los resultados de la población, se observa que existe un subconjunto de individuos que evolucionó la conducta de emitir preferentemente a aquellos que presentaban un parentesco de 1 y 0.8, es decir, que eran del mismo color o de un color parecido. Si normalizamos la emisión de los individuos de acuerdo a su emisión máxima y mínima en la totalidad de las condiciones de prueba (720), se puede apreciar esta preferencia.

En contraste, aquellos que presentaban parentesco de 0.6 y menor no presentan una discriminación tan precisa y no existen diferencias significativas en la gran mayoría de las condiciones, aunque se observa una tendencia a emitir más en aquellas condiciones con un parentesco mayor. La falta de precisión en el mecanismo de discriminación por parentesco se debe probablemente a la simplicidad de nuestra red neuronal, así como al hecho de que los individuos de este experimento solo perciben el color del otro robot y no el propio, lo que dificulta aún más la tarea.

Este hecho será demostrado en el experimento 5, en el cual estos dos factores cambian y dicho mecanismo se vuelve mucho más preciso. A diferencia del experimento 1 en el que el parentesco fue proporcionado directamente al otro robot como un valor numérico, en este experimento los individuos debieron evolucionar un mecanismo que les permitiera identificar a otros individuos que se parecen genéticamente a ellos usando solo la expresión fenotípica de los genes de estos el color. Esto demuestra que no es necesario tener como fuente de la red neuronal el fenotipo del propio robot realizando esta conducta, aunque, como demostrará el experimento 5 (4.31) también es posible evolucionarlo en estas condiciones. Esto ocurre en la mayoría de las 36 condiciones por separado y agrupadas cuando consideramos el parentesco; sin embargo, es importante tener en cuenta que la regla de Hamilton no se cumple en lo que respecta a la cantidad de comida presente en el entorno, tanto cuando se toman las 36 condiciones por separado como cuando se agrupan.

4.3.8. Graficar las poblaciones finales del experimento 2

Al igual que en los experimentos anteriores, utilizamos el SOM para graficar la posición de cada individuo en el espacio de solución. En este caso, generamos las coordenadas mediante el mismo SOM que se utilizó para asignar el color a los robots durante el proceso evolutivo.

Una vez que tenemos las coordenadas de todos los individuos de cada generación, procedemos a graficarlas para observar cómo se comportan nuestras poblaciones a lo largo del tiempo durante su evolución. Mostramos los cambios en pasos de 100 generaciones para una corrida de cada una de nuestras condiciones evolutivas, 4 en total para cada condición.

En la primera generación, todos los individuos se encuentran esparcidos por el espacio de solución, lo cual es lo esperable, ya que la primera generación de cada población fue creada de forma aleatoria y ninguna fuerza evolutiva ha actuado sobre ella. A medida que transcurren las generaciones, se puede observar cómo los individuos comienzan a agruparse debido a las presiones selectivas.

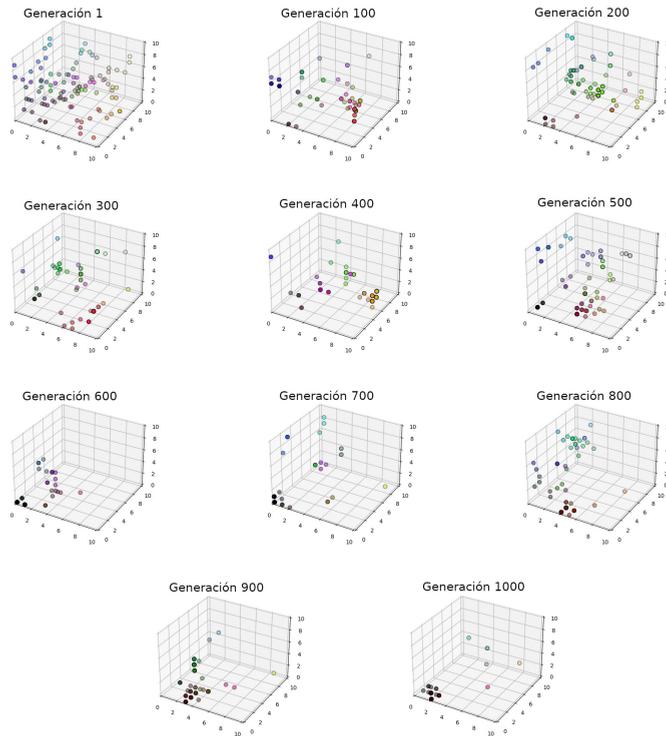


Figura 4.24: Posiciones para cada uno de los individuos producidos por una corrida del algoritmo evolutivo para una de las poblaciones evolucionadas bajo la condición de abundancia de comida percibiendo el color del otro robot. El espacio de solución es representado por un SOM, cada punto representa a un nodo ganador cuando un individuo de la población es usado como entrada, el color de los puntos es color que le fue asignado a cada individuo durante las simulaciones y su intensidad, el número de individuos que ocupan esa misma posición.

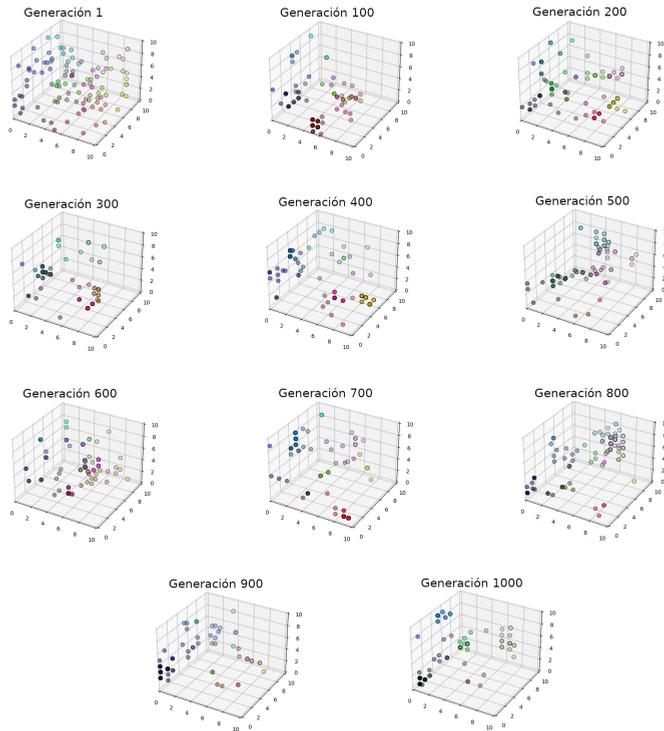


Figura 4.25: Posiciones para cada uno de los individuos producidos por una corrida del algoritmo evolutivo para una de las poblaciones evolucionadas bajo la condición de comida variable percibiendo el color del otro robot. El espacio de solución es representado por un SOM, cada punto representa a un nodo ganador cuando un individuo de la población es usado como entrada, el color de los puntos es color que le fue asignado a cada individuo durante las simulaciones y su intensidad el número de individuos que ocupan esa misma posición.

4.4. Experimento 3, percibiendo el color de ambos robots, red con una capa oculta

En este experimento, la red neuronal de los robots recibió el color del otro robot presente en el escenario y la del propio robot. La intención de esta configuración era facilitar la tarea de reconocer el nivel de parentesco entre ellos y que este pudiera ser utilizado como un mecanismo de discriminación por parentesco en la realización de conductas altruistas.

4.4.1. Entorno y robots experimento 3

Al igual que en los experimentos anteriores, los robots disponían de una cámara de 360 grados, dos ruedas con motores diferenciales, y eran capaces de detectar que se encuentran en la región de interés gracias al sensor que apunta al suelo, con la diferencia de que la red está informada de cuánta comida hay en la región de interés.

Red neuronal

En el experimento actual, la red neuronal de los robots está siendo informada tanto del color del otro robot presente en el escenario como del color del propio robot. En consecuencia, se optó por una red neuronal que alberga una arquitectura lo más parecida a la del experimento anterior. Siendo esta una red neuronal *feedforward full connected* de 3 capas 4.16, con una capa de entrada, una capa oculta y una capa de salida, igual que en el caso anterior todas las neuronas de la red usaron una función de activación sigmoide $(\frac{1}{1+e^{-x}} - 0.5) * 2$, donde x era la sumatoria de la salida de las neuronas de la capa anterior multiplicada por el peso de su conexión a esa neurona, la cual devolvía valores entre -1 y 1.

Capa de entrada La capa de entrada estaba compuesta por 15 neuronas. Estas neuronas recibían la presencia de luz azul procedente de la cámara 360. La luz fue preprocesada dividiéndola en 9 fragmentos, cada uno correspondiente a 40 grados de la imagen. Si alguno de ellos contenía luz azul, la neurona correspondiente aumentaba su activación en 1, mientras que sus dos neuronas vecinas sumaban 0.6 a su activación.

Las siguientes 3 neuronas de la capa de entrada recibían los valores de color del otro robot presente en el entorno, mientras que las tres subsecuentes recibían los valores de color del propio robot. Estos valores se determinaron a través del uso de un mapa autoorganizado cuya estructura y entrenamiento se describen en la **sección 3.2**. Las últimas tres neuronas de esta capa recibían la cantidad de comida presente en la región de interés.

Capa oculta La capa oculta estaba compuesta por un total de 12 neuronas, cada una de ellas conectada a todas las neuronas de la capa de entrada y la capa de salida.

Capa de salida La capa de salida presentaba una estructura similar a la de experimentos previos. Las primeras dos neuronas determinaron la velocidad de los motores del robot. Esta se calculó mediante la multiplicación

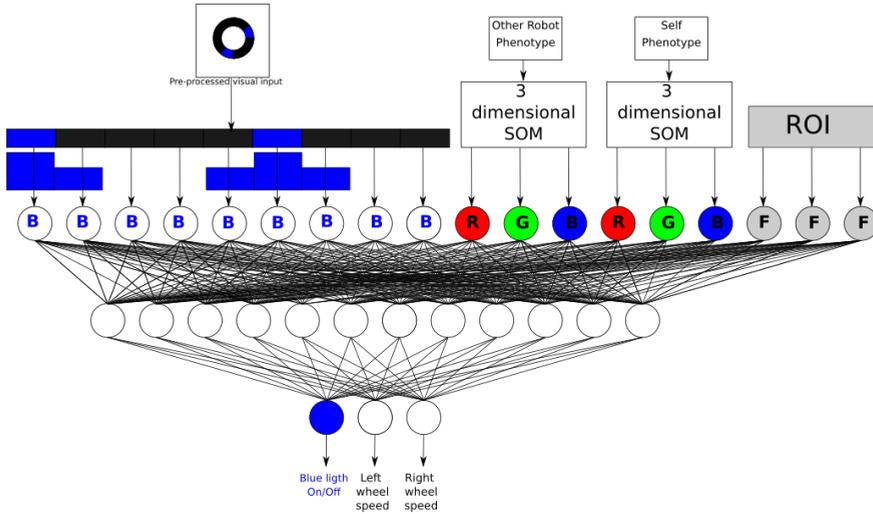


Figura 4.26: Red Neuronal para experimentos de barba verde conociendo el color del otro robot y el propio.

de la salida de estas neuronas por 15, con el fin de obtener un rango de velocidad de -15 a 15 en cada motor. La neurona restante tenía la función de determinar si el anillo de LED se encendía o se apagaba. Los valores de salida inferiores a cero apagaban el anillo de LED, mientras que los valores superiores a cero lo encendían.

Escenario

El entorno simulado tenía un tamaño de $2 m^2$ y contaba con una región de interés de $30 cm$ de diámetro en el centro del entorno. La aptitud del robot estaba directamente relacionada con el tiempo que pasaba sobre dicha región.

Asignación de color

En el experimento 2 se llevó a cabo la asignación del color a cada uno de los robots pertenecientes a una generación, previamente a las simulaciones. Se utilizó un nuevo SOM entrenado, como se indica en la **sección 3.2**, que representa el espacio de solución del problema para las redes neuronales posibles en el experimento 3, al igual que en el experimento 2.

Condiciones de evolución		
Cantidad de alimento para cada condición	Abundancia	Promedio
	1	1-2
Número de procesos evolutivos	4	
Individuos por generación	100	
Porcentaje de mutación	1.8 %	
Número de generaciones	1000	

Cuadro 4.24: Condiciones de evolución para cada condición de evolución en el experimento 3.

4.4.2. Variables durante el proceso de evolución del experimento 3

Cantidad de comida y ciclos de vida

Al igual que en el experimento 2, evolucionamos las poblaciones bajo dos condiciones distintas: condición de abundancia y condición de comida variable (ver tabla 4.24). En la condición de abundancia de comida, la cantidad de comida en la región de interés fue de 2 unidades, mientras que en la condición de comida promedio, la cantidad de comida en la región de interés varió de forma aleatoria entre 1 y 2 en cada una de las simulaciones de cada robot.

Función de aptitud Se utilizó la misma función de aptitud que en los experimentos previos (**ver formula 4.5**):

$$Aptitud\ Total = \sum_{i=0}^n (A_i = \begin{cases} (\frac{P_i * C}{R_i}) & \text{si } A_i < 1 \\ 1 & \text{en otro caso} \end{cases}) \quad (4.5)$$

Selección y cruza Al igual que en los experimentos anteriores, se utilizó un criterio de selección elitista, con un porcentaje de selección del 50 % de la población. Igualmente, se formaron un número de parejas equivalente al 50 % de la población, y, cada una de ellas produjo 2 hijos para mantener el tamaño de la población.

Mutación. La mutación de los individuos nuevamente se mantuvo en 1.8 %.

Duración del algoritmo y condición de paro. Dado que se consideraba una complejidad de la tarea similar a la observada en el experimento 2 y teniendo en cuenta un proceso de evolución “*open ended*”, establecimos la condición de paro en 1000 generaciones.

Los robots desempeñaron el papel de señalizador y forrajero con todos los robots de su misma generación, con un total de 198 simulaciones por robot. Asimismo, al igual que en los experimentos anteriores, se evolucionaron de forma autónoma cuatro poblaciones por condición con el fin de reducir los efectos del azar.

4.4.3. Pruebas para determinar si la emisión de luz es una señal confiable de comida en el experimento 3

Como en experimentos previos, es necesario determinar si los robots adquirieron la capacidad de localizar la región de interés a través de la presencia de luz azul, con el objetivo de determinar si esta es una señal fiable de la presencia de comida y, por ende, si una señal altruista es una señal confiable de la presencia de comida.

Procedimiento

Para verificar la confiabilidad de la señal, se tomaron robots pertenecientes a las generaciones de alta entropía, baja entropía, alta emisión y baja emisión de cada una de las 4 poblaciones evolucionadas. Se llevó a cabo la misma tarea de forrajeo para cada una de ellas durante su evolución (ver figura 4.17), bajo dos condiciones: la primera llamada “luz encendida”, en la que el robot señalizador siempre emitía luz azul, y otra condición llamada “a ciegas”, en la que el robot señalizador siempre mantenía su anillo de LED apagado.

Condición luz encendida

En esta condición, los robots de la última generación de cada una de nuestras poblaciones volvieron a desempeñar la misma tarea con los mismos parámetros y el mismo escenario en el que evolucionaron. La única diferencia es que el robot que cumple el papel de señalizador siempre tenía la luz azul de su anillo de LED encendida, sin importar cuáles fueran las salidas de su red neuronal.

Al igual que durante el proceso evolutivo, cada robot cumple el papel de señalizador con todos los otros robots de su población, 99 veces como

señalizador y 99 veces como forrajero. Cabe destacar que lo que nos interesa evaluar en esta condición es la cantidad de tiempo que los robots pasan en la región de interés cuando desempeñaron el papel de forrajero.

Condición a ciegas

Se utilizó esta condición como línea base para determinar si las poblaciones de robots previamente evolucionadas estaban realmente utilizando la luz azul para encontrar la región de interés. Para este propósito, utilizamos el mismo escenario, parámetros y procedimientos utilizados durante la condición de luz encendida. La única diferencia radica en que el anillo de LED azules de los robots que desempeñaron la función de señalizador se encontraba apagado durante todo el período de tiempo que transcurrieron las simulaciones. Al igual que en la prueba anterior, solo nos interesaba medir el tiempo que el robot que desempeñó el papel de forrajero pasó dentro de la región de interés.

Resultados de la condición luz encendida vs a ciegas

Se llevó a cabo una prueba t de medidas repetidas para cada una de las poblaciones que llevaron a cabo las tareas, comparando el número de ciclos normalizados que los robots pasaron dentro de la región de interés cuando desempeñaron el rol de forrajero entre la condición “a ciegas” y la condición de “luz encendida” (ver Fig. 4.27).

En la condición de abundancia de comida, se encontraron diferencias significativas entre la cantidad de ciclos que los robots estuvieron dentro de la región de interés en la condición luz encendida ($M = 0.3799, SD = 0.3485$) y la cantidad de ciclos que estuvieron en la región de interés en la condición a ciegas ($M = 0.1557, SD = 0.1636$); $p < 0.01$.

En cambio, durante la condición de comida variable, no se encontraron diferencias entre la cantidad de ciclos que los robots pasaron dentro de la región de interés en la condición luz encendida ($M = 0.10299, SD = 0.1265$) y la cantidad de ciclos que pasaron en la región de interés en la condición a ciegas ($M = 0.1063, SD = 0.1252$); $p = 0.2026$.

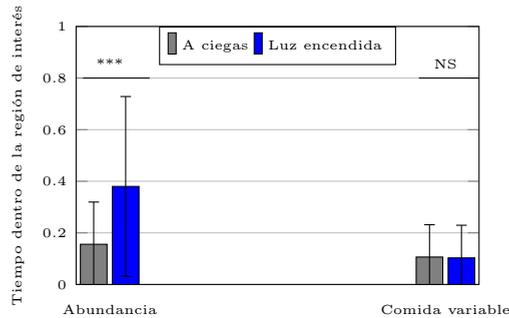


Figura 4.27: Diferencias entre las condiciones “luz encendida” y “a ciegas”, para cada uno de los cuatro grupos evolucionados, una prueba t de medidas repetidas fue realizada para ver las diferencias entre el número de ciclos que los robots pasan dentro de la región de interés para cada condición, los bigotes de la gráfica muestran la desviación estándar, *** $p < 0.01$.

4.4.4. Pruebas para determinar el nivel de altruismo en el experimento 3

Dado que en la condición de comida variable la luz azul no evolucionó como una señal fiable de la presencia de comida, solo realizamos esta prueba para las poblaciones evolucionadas bajo la condición de comida abundante.

Se utilizó un diseño experimental 1×6 (6 niveles de parentesco con 2 unidades de comida en la región de interés). Los grupos fueron formados por las poblaciones de la última generación de cada algoritmo evolutivo, que eran 4 de 100 individuos por condición, y totalizaron 400 individuos por grupo.

Cada robot de cada uno de estos grupos desempeñó 20 veces el papel de señalizador para cada una de las condiciones experimentales. La tarea, el entorno y los parámetros empleados fueron similares a los utilizados durante el proceso evolutivo. La región de interés contenía 2 unidades en todas las condiciones y fueron evaluados bajo 6 distintos niveles de “parentesco” (ver tabla 4.25).

Manipulación del parentesco

Para manipular el parentesco del otro robot presente en el entorno, utilizamos el mismo procedimiento que en el experimento previo. Generamos nuevos robots modificando los valores del fenoma del robot que realizó la prueba mediante la mutación de un porcentaje de su fenoma. Con este mé-

Pruebas de altruismo, condición de abundancia						
Parentesco con el otro robot	1	0.8	0.6	0.4	0.2	0
Cantidad de comida	2					

Cuadro 4.25: Condiciones de prueba para determinar nivel de altruismo en la condición de abundancia

todo, generamos un nuevo robot para cada una de las 20 simulaciones que cada robot realizó por cada condición experimental. Estos “nuevos robots” desempeñaron el papel de forrajeros, mientras que el individuo a medir desempeñó el papel de señalizador.

Al igual que en el experimento previo, estos “nuevos robots” solo tuvieron la función de servir para medir el comportamiento de la población ya evolucionada. Por lo tanto, no nos interesa evaluar su rendimiento.

El factor más importante a calcular es el nivel de emisión de luz azul cuando el robot señalizador está en la región de interés y el robot forrajero está fuera de la misma.

Resultados experimento 3

Debido a que lo que nos interesaba era medir la conducta de los robots altruistas, tomamos al 20 % de robots que más emitieron dentro de la región de interés de cada una de las poblaciones, a través de todas las condiciones.

Para la condición de abundancia de comida, los promedios de emisión fueron los siguientes (**Fig.4.4.4**): Los robots en la condición parentesco 1 tuvieron una emisión de 79.0236 % ($SD = 40.0832$), en la condición parentesco 0.8 los robots tuvieron una emisión de 79.3850 % ($SD = 36.6810$), en la condición parentesco 0.6 los robots tuvieron una emisión de 79.5903 % ($SD = 36.6810$), en la condición parentesco 0.4 los robots tuvieron una emisión de 80.5228 % ($SD = 36.3888$), en la condición parentesco 0.2 los robots tuvieron una emisión de 80.6615 % ($SD = 36.3445$), en la condición parentesco 0 los robots tuvieron una emisión de 80.4375 % ($SD = 35.8460$).

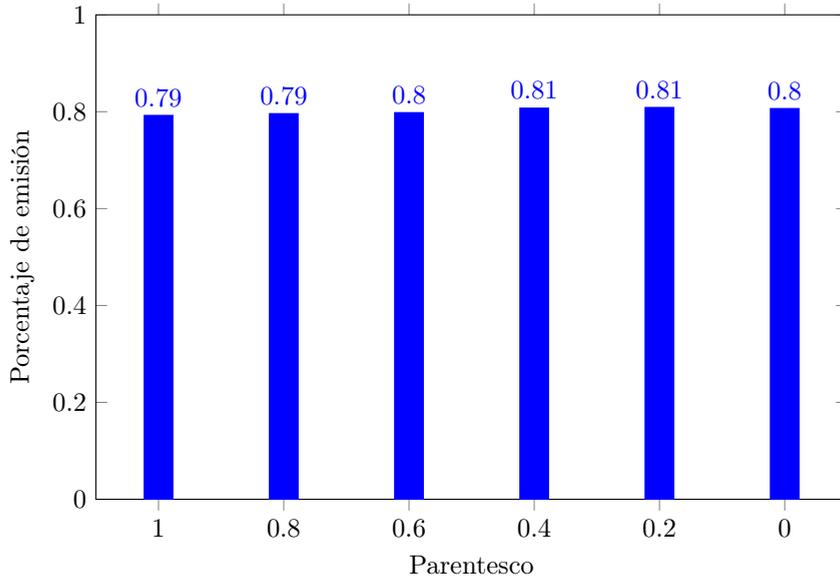


Figura 4.28: Promedio de emisión de luz según el parentesco percibido en la población evolucionada en la condición de abundancia percibiendo el parentesco de ambos robot

Graficar las poblaciones finales

Sin embargo, a diferencia de lo que ocurre en tres de las condiciones abundancia percibiendo el color del otro robot (fig. 4.24), comida variable percibiendo el color del otro robot (fig. 4.25), y abundancia percibiendo el color de ambos robots (fig. 4.29), en las que los individuos parecen agruparse de forma definida, los individuos de la condición evolucionada en la comida variable que percibe ambos parentescos permanecen más dispersos por el espacio de soluciones, y los grupos que se forman parecen menos definidos (fig. 4.30).

El fenómeno de falta de convergencia puede explicarse de la siguiente manera: al no haber evolucionado la emisión de luz azul como una señal confiable de la presencia de comida, esto provocó que tampoco evolucionara una conducta eficiente de forrajero, lo cual a su vez disminuye las presiones selectivas hacia toda la población. Como resultado, aquellos que normalmente no podrían competir en una población de forrajeros eficientes logran pasar sus genes a las siguientes generaciones; asimismo, se vuelve innecesario para estos individuos aprender a apagar o prender la luz de su anillo de

LED en casos específicos, lo cual disminuye aún más las presiones selectivas comparadas con los grupos en los que la evolución de dichas conductas se produce.

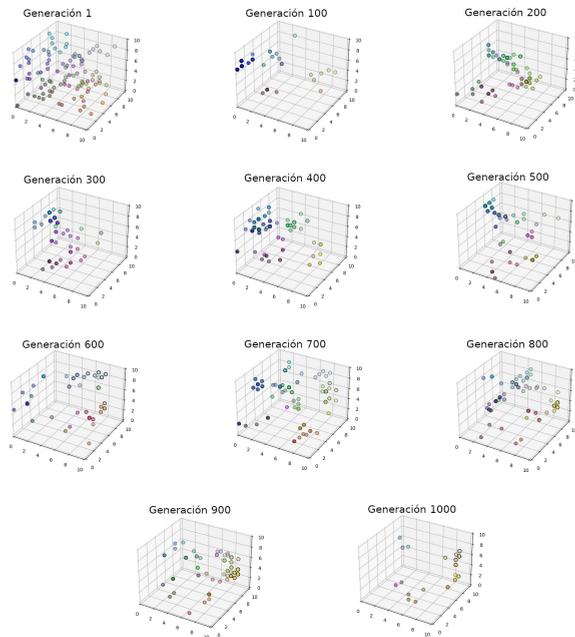


Figura 4.29: Posiciones para cada uno de los individuos producidos por una corrida del algoritmo evolutivo para una de las poblaciones evolucionadas bajo la condición de abundancia, percibiendo el color de ambos robots. El espacio de solución es representado por un **SOM**, cada punto representa a un nodo ganador cuando un individuo de la población es usado como entrada, el color de los puntos es color que le fue asignado a cada individuo durante las simulaciones y su intensidad, el número de individuos que ocupan esa misma posición.

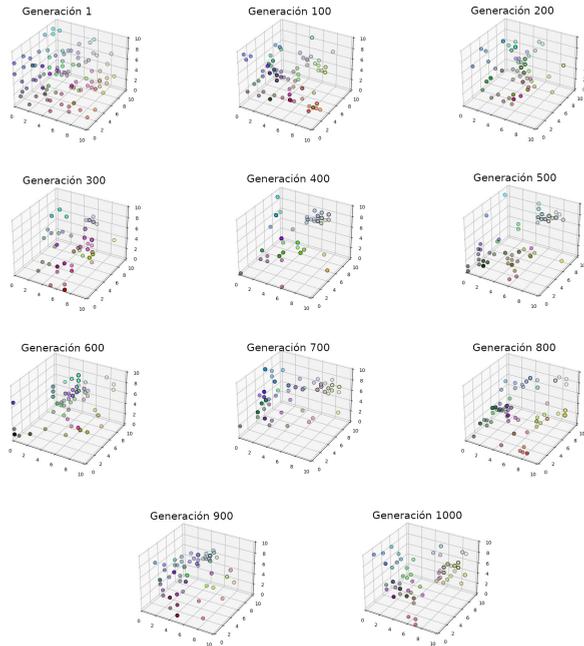


Figura 4.30: Posiciones para cada uno de los individuos producidos por una corrida del algoritmo evolutivo para una de las poblaciones evolucionadas bajo la condición de comida percibiendo el color de ambos robots. El espacio de solución es representado por un **SOM**, cada punto representa a un nodo ganador cuando un individuo de la población es usado como entrada, el color de los puntos es color que le fue asignado a cada individuo durante las simulaciones y su intensidad, el número de individuos que ocupan esa misma posición.

4.5. Experimento 4, percibiendo el color del otro robot, red con dos capas ocultas

Una de las interrogantes planteadas durante la realización del experimento 2 fue que la red neuronal empleada no era lo suficientemente compleja para que se pueda detectar diferencias significativas en la emisión de luz azul en la región de interés, basado en la relación de parentesco entre los robots presentes en el escenario. Por esta razón, en este experimento decidimos incrementar la cantidad de capas ocultas en nuestra red neuronal.

4.5.1. Entorno y robots experimento 4

Al igual que en los experimentos anteriores, los robots disponían de una cámara de 360 grados, dos ruedas con motores diferenciales, y eran capaces de detectar que se encuentran en la región de interés gracias al sensor que apunta al suelo, con la diferencia de que la red está informada de cuánta comida hay en la región de interés.

Red neuronal del experimento 4

En el experimento 4 se utilizó una red neuronal *feedforward fully connected* de 4 capas: una capa de entrada, dos capas ocultas y una capa de salida. Al igual que en los experimentos previos, se utilizó una función sigmoide $(\frac{1}{1+e^{-x}} - 0.5) * 2$, siendo x la sumatoria de la salida de las neuronas de la capa anterior multiplicada por el peso de su conexión a esa neurona. Esta función devolvía valores entre -1 y 1 .

Capa de entrada La capa de entrada cuenta con 15 neuronas. Nueve de ellas recibían la presencia de luz azul proveniente de la cámara 360, la cual fue pre-procesada dividiéndola en 9 fragmentos, cada uno correspondiente a 40 grados de la imagen. En caso de que alguno de ellos contuviera luz azul, la neurona correspondiente recibía una activación de 1, mientras que sus dos neuronas vecinas inmediatas aumentaban su activación en 0.6. Las siguientes tres neuronas de la capa de entrada recibían los valores de color del otro robot presente en el escenario. Al igual que en experimentos previos, este valor se determinó a través del uso de un mapa autoorganizado (**sección 3.2**). Las últimas tres neuronas de esta capa recibían el valor correspondiente a la cantidad de comida presente en la región de interés cuando el robot se encontraba sobre ella y 0 cuando no.

Capas ocultas Cada una de estas dos capas estaba conformada por un total de 12 neuronas, cada una de ellas conectada a todas las neuronas de la capa de entrada y la capa de salida.

Capa de salida La capa de salida mantuvo la misma estructura que en experimentos previos, siendo las primeras dos neuronas las que determinaron la velocidad de los motores del robot. Esta medida se calculó mediante la multiplicación de la salida de estas neuronas por 15, con el fin de obtener un rango de velocidad de -15 a 15 en cada motor. La neurona adicional desempeñaba la función de determinar si el anillo de leds se encendía o

se apagaba; valores de salida superiores a cero apagaban el anillo de leds, mientras que valores superiores a cero lo encendían.

Escenario

Al igual que en los experimentos previos, el escenario era un entorno simulado con un tamaño de 2 m^2 , con una región de interés de 30 cm de diámetro en el centro del entorno que representaba un comedero.

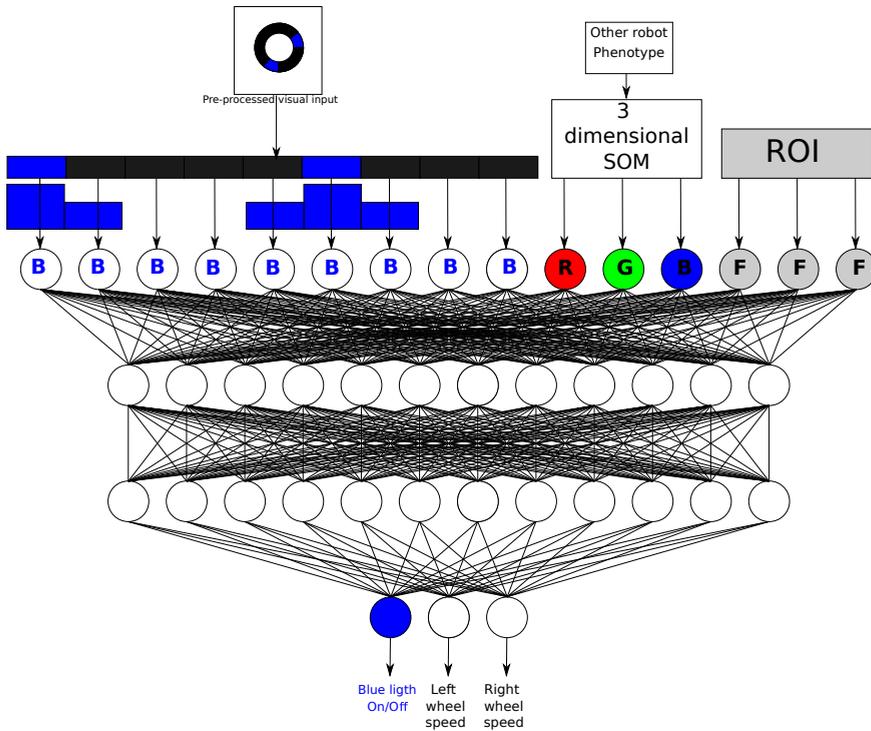


Figura 4.31: Red neuronal del experimento 4 (conociendo el color del otro robot), red con 2 capas ocultas.

Asignación de color

Antes de las simulaciones, se asignó un color a cada uno de los robots de una generación previa. Para ello, se entrenó un nuevo SOM, tal como se

describe en la **sección 3.2**.

4.5.2. Variables durante el proceso de evolución

Cada uno de los procesos evolutivos abarcó una población de 100 individuos durante 1000 generaciones, con una mutación del 1.8%. La cantidad de comida presente en la región de interés oscilaba aleatoriamente entre 1 y 2, con variaciones en múltiplos de 0.1 en cada simulación de cada robot. En todas las condiciones, todos los robots desempeñaron el papel de señalizador y forrajero con todos los demás robots de su misma generación. Se evolucionaron cuatro poblaciones por condición para mitigar los efectos del azar, lo que resultó en un total de 198 simulaciones por robot (99 como señalizador y 99 como forrajero).

Condiciones de evolución	
Cantidad de alimento	1-2
Número de procesos evolutivos	4
Individuos por generación	100
mutación	1.8 %
Número de generaciones	1000

Cuadro 4.26: Condiciones de evolución para el experimento 4.

Pruebas para determinar si la emisión de luz es una señal confiable de comida

Para verificar la fiabilidad de la señal, se tomaron robots pertenecientes a las generaciones de alta entropía, baja entropía, alta emisión y baja emisión de cada una de las 4 poblaciones evolucionadas. Se realizó la misma tarea de forrajero utilizada durante su evolución (ver Figura 4.17) bajo dos condiciones: la primera llamada “luz encendida”, donde el robot señalizador siempre emitía luz azul, y otra condición llamada “a ciegas”, en la que el robot señalizador siempre mantenía su anillo de LEDs apagado.

Condición luz encendida

Los robots de la última generación de cada una de las poblaciones volvieron a realizar la misma tarea con los mismos parámetros y el mismo entorno en el que evolucionaron. La única diferencia fue que el robot que

desempeñaba el papel de señalizador siempre tenía la luz azul de su anillo de LEDs encendida, independientemente de cuáles fueran las salidas de su red neuronal.

Al igual que durante el proceso evolutivo, cada robot desempeñó el papel de señalizador con todos los demás robots de su población como señalizador y forrajero. Es relevante destacar que en esta situación nos interesa medir la cantidad de tiempo que los robots pasan en la región de interés al desempeñar el papel de forrajero.

Condición a ciegas

Se utilizó esta condición como línea base para determinar si las poblaciones de robots previamente evolucionadas estaban realmente utilizando la luz azul para encontrar la región de interés. Con este propósito, utilizamos el mismo escenario, parámetros y procedimientos utilizados durante la condición de luz encendida. Con la diferencia de que el anillo de LED azules de los robots que desempeñan el papel de señalizador estaba apagado durante todo el tiempo que duraron las simulaciones. Como se ha mencionado en la prueba anterior, solo nos interesaba evaluar el tiempo que el robot que desempeña la función de forrajero pasa dentro de la zona de interés.

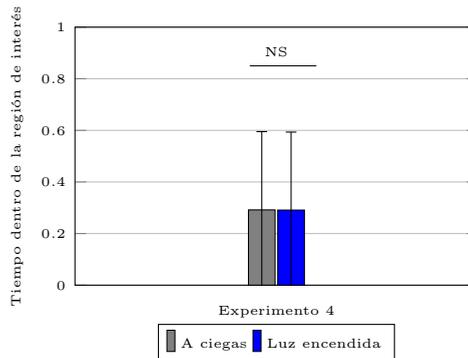


Figura 4.32: Diferencias entre las condiciones “luz encendida” y “a ciegas”, para los robots que solo perciben el color del otro robot, una prueba t de medidas repetidas fue realizada para ver las diferencias entre el número de ciclos que los robots pasan dentro de la región de interés para cada condición, los bigotes de la gráfica muestran la desviación estándar, $p = 0.806$.

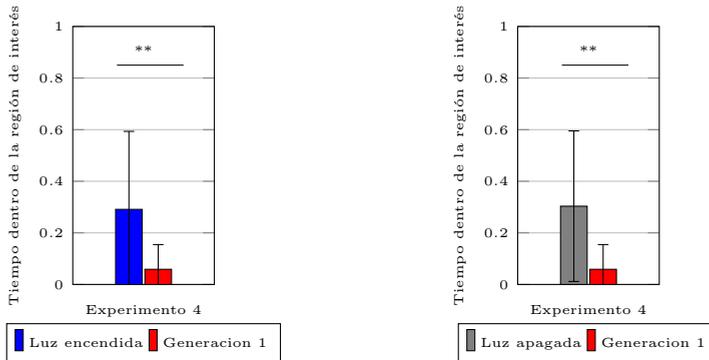


Figura 4.33: Diferencias entre las condiciones “luz encendida” vs “generación 1”, y, “luz apagada” vs “generación 1” y para los robots que solo perciben el color del otro robot, una prueba t fue realizada para ver las diferencias entre el número de ciclos que los robots de cada grupo pasan dentro de la región de interés, los bigotes de la gráfica muestran la desviación estándar, $** p < 0.001$.

Resultados de las condiciones luz encendida y a ciegas

Se llevó a cabo una prueba t de medidas repetidas para cada una de las poblaciones que realizaron ambas tareas, comparando el número de ciclos normalizados que los robots pasaron dentro de la región de interés, cuando desempeñaron el rol de forrajero entre la condición “a ciegas” comparada con la condición de “luz encendida”. Como se puede apreciar en la tabla 4.32, no se encontraron diferencias significativas entre las dos condiciones, lo cual nos llevó a preguntarnos si en realidad el algoritmo había logrado evolucionar la conducta de encontrar la región de interés a ciegas o simplemente no se había logrado evolucionar ninguna conducta.

Con el fin de descartar la posibilidad de que la ausencia de diferencias entre las condiciones de luz encendida y luz apagada se deba a la incapacidad de nuestros robots de evolucionar ninguna conducta, hemos llevado a cabo una evaluación de la conducta de la primera generación de cada una de nuestras cuatro ejecuciones de algoritmo evolutivo. Y lo contrastamos mediante una prueba t , con los resultados de la condición luz encendida y luz apagada para las poblaciones ya evolucionadas. Como se puede ver en la figura 4.33, encontramos diferencias significativas para ambas comparaciones.

También hay que destacar que cuando observamos el comportamiento de la primera generación de nuestras cuatro ejecuciones del algoritmo evolutivo

por separado, y los comparamos con las poblaciones evolucionadas para esa corrida del algoritmo evolutivo, vemos que en todos los casos obtenemos los mismos resultados, y el comportamiento de la primera generación de cada una de ellas es significativamente peor encontrando la región de interés. Lo cual indica que, a pesar de no haber evolucionado una conducta altruista ni la habilidad de encontrar la región de interés mediante la utilización de la luz azul, el algoritmo evolutivo fue capaz de utilizar las entradas de la red neuronal para evolucionar una conducta de localizar la región de interés mediante la navegación a ciegas en cuatro ejecuciones inicializadas aleatoriamente, tal como se ilustra en las gráficas (véase la fig. 4.34). Estos resultados no minan el valor predictivo de la regla de Hamilton, solo demuestran nuevamente la enorme capacidad que tienen los algoritmos evolutivos de explotar condiciones del entorno para dar con soluciones inesperadas a un problema.

4.5.3. Pruebas de altruismo experimento 4

Debido a la ausencia de diferencias entre la condición de luz encendida y a ciegas, y a que la solución encontrada por nuestro algoritmo evolutivo para este experimento en las cuatro ejecuciones del algoritmo evolutivo fue la navegación a ciegas del entorno, no podemos considerar, según nuestra definición de señal fiable, que la emisión de luz azul sea una señal fiable de la presencia de comida. Por lo tanto, emitir luz azul en la región de interés no puede considerarse un comportamiento altruista. En consecuencia, medir la emisión de luz azul que realizan los robots en la región de interés carece de sentido, porque no transmite ninguna información útil al otro robot presente en el entorno. Por lo tanto, la presencia o ausencia de este comportamiento en nuestras poblaciones carece de significado.

4.6. Experimento 5, percibiendo el color de ambos robots, red con dos capas ocultas

Al igual que en el experimento 3, para este experimento la red neuronal de los robots conoce el color de los dos robots presentes en el escenario, pero, debido a que en el experimento 3 en la condición de comida variable no evoluciono la conducta de encontrar la comida utilizando la luz azul, decidimos aumentar el número de capas ocultas de la red.

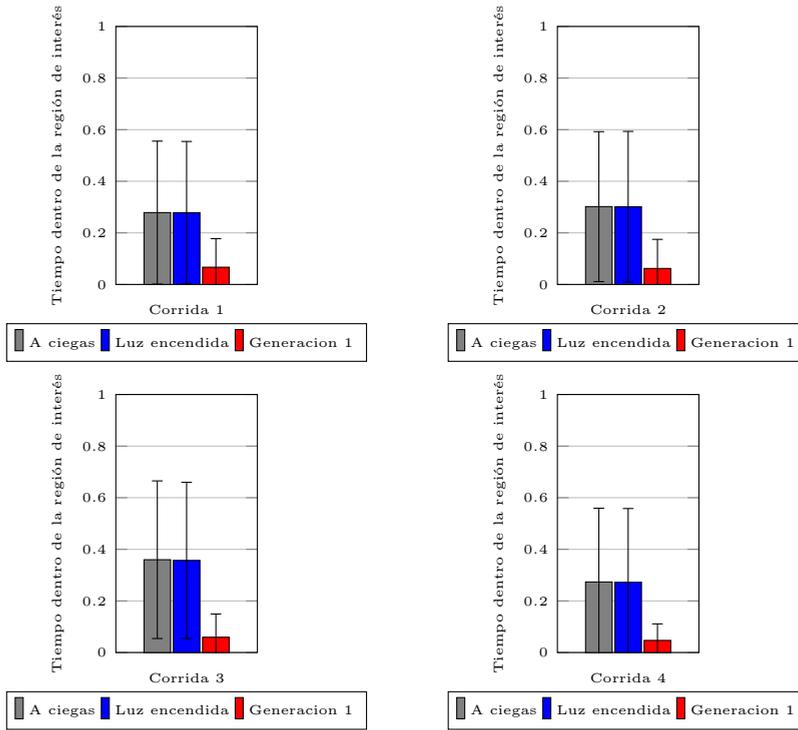


Figura 4.34: Diferencias entre las condiciones “luz encendida”, generación 0 y “a ciegas”, para los robots que solo perciben el color del otro robot, para cada una de las ejecuciones del algoritmo evolutivo.

4.6.1. Entorno y robots experimento 4

Como en los experimentos anteriores, los robots disponían de una cámara de 360 grados, dos ruedas con motores diferenciales, y eran capaces de detectar que se encuentran en la región de interés gracias al sensor que apunta al suelo, con la diferencia de que la red está informada de cuánta comida hay en la región de interés.

Red neuronal experimento 5

En el experimento 5 se utilizó una red neuronal *feedforward fully connected* de 4 capas, con una capa de entrada, dos capas ocultas y una capa de salida, al igual que en todos los experimentos previos. Las neuronas

de la red utilizaron una función de activación sigmoidea, definida como $(\frac{1}{1+e^{-x}} - 0.5) * 2$, donde x es la sumatoria de la salida de las neuronas de la capa anterior multiplicada por el peso de su conexión a esa neurona. Esta función devuelve valores entre -1 y 1, lo que permite que la red neuronal pueda aprender a partir de los datos de entrada y generar una salida adecuada para el problema en cuestión.

Capa de entrada En la capa de entrada de la red neuronal del experimento 5, se utilizaron 18 neuronas. Las primeras 9 neuronas recibían información sobre la presencia de luz azul proveniente de la cámara 360, pre procesada. Cada una de estas neuronas representaba la presencia de luz azul correspondiente a un segmento de 40 grados de la imagen. Cuando una neurona detectaba luz azul, su activación se establecía en 1, y las dos neuronas vecinas inmediatas aumentaban su activación en 0.6. Las siguientes 3 neuronas de esta capa recibían el valor correspondiente a la cantidad de comida presente en la región de interés cuando el robot se encontraba sobre ella y 0 cuando no. Las últimas 3 neuronas de la capa de entrada recibían los valores de color del otro robot presente en el escenario, los cuales se determinaron a través del uso de un mapa autoorganizado (ver sección 3.2).

Capas ocultas Las capas ocultas estaban conformadas por un total de 12 neuronas, cada una de ellas conectada a todas las neuronas de la capa anterior y la capa siguiente.

Capa de salida En la capa de salida, se mantuvo la misma estructura que en experimentos previos. Las primeras 2 neuronas controlaban la velocidad de los motores del robot, mientras que la neurona restante determinaba si el anillo de leds se encendía o se apagaba. Valores de salida menores que cero apagaban el anillo de leds, mientras que valores mayores a cero lo encendían.

Escenario

Al igual que en los experimentos previos, el escenario era un entorno simulado con un tamaño de $2 m^2$, con una región de interés de $30 cm$ de diámetro en el centro del entorno que representaba un comedero.

4.6.2. Variables durante el proceso de evolución

En cuanto a las variables durante el proceso de evolución, al igual que en el experimento 4, cada uno de los procesos evolutivos contó con poblaciones

de 100 individuos durante 1000 generaciones, con una tasa de mutación del 1.8%. La cantidad de comida presente en la región de interés variaba aleatoriamente entre 1 y 2 con variaciones en múltiplos de 0.1 en cada una de las simulaciones de cada robot. En todas las condiciones, al igual que en experimentos previos, todos los robots desempeñaron el papel de señalizador y de forrajero con todos los demás robots de su misma generación, para un total de 198 simulaciones por robot (99 como señalizador y 99 como forrajero). Se evolucionaron 4 poblaciones por condición para mitigar los efectos del azar.

Condiciones de evolución	
Cantidad de alimento	1-2
Número de procesos evolutivos	4
Individuos por generación	100
mutación	1.8%
Número de generaciones	1000

Cuadro 4.27: Condiciones de evolución en el experimento 5.

4.6.3. Pruebas para determinar si la emisión de luz es una señal confiable de comida

Al igual que en experimentos anteriores, debemos determinar si los robots aprendieron a encontrar la región de interés a través de la presencia de luz azul. Para saber si esta es una señal confiable de la presencia de comida y, por lo tanto, si el hecho de emitir luz azul cuando se desempeña el papel de señalizador es un comportamiento altruista, realizamos las siguientes pruebas.

Tomamos a los robots pertenecientes a las generaciones de alta emisión de luz y realizamos la misma tarea de forrajero utilizada durante su evolución (ver Figura 4.17), bajo dos condiciones: la primera llamada “luz encendida”, donde el robot señalizador siempre emitía luz azul, y otra condición llamada “a ciegas”, en la que el robot señalizador siempre mantenía su anillo de leds apagado.

Con este propósito, para verificar la confiabilidad de la señal, realizamos la tarea de forrajero con todas las 4 poblaciones evolucionadas. En ambas condiciones, solo nos interesa evaluar el tiempo que el robot que desempeña el papel de forrajero pasó dentro de la región de interés.

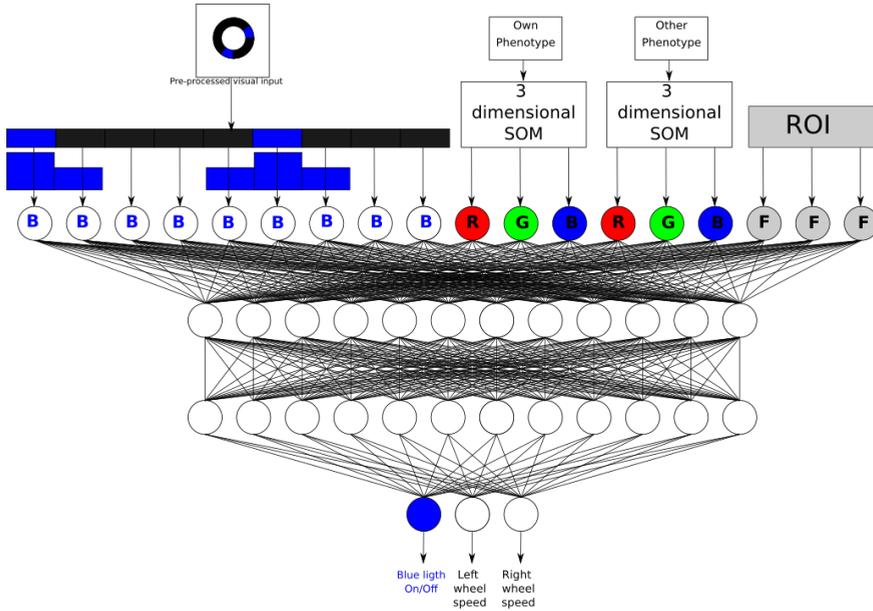


Figura 4.35: Red neuronal experimento 5 (conociendo el color del otro robot), red con 2 capas ocultas.

Condición luz encendida

En esta condición, los robots de la última generación de cada población desempeñaron la misma tarea que durante la evolución, pero con una diferencia: el robot que desempeñaba el papel de señalizador siempre tenía la luz azul de su anillo de LEDs encendida, independientemente de las salidas de su red neuronal. Cada robot desempeñó el papel de señalizador con todos los demás robots de su población, 99 veces como señalizador y 99 veces como forrajero. Es importante señalar que lo que nos interesa medir en esta condición es la cantidad de tiempo que los robots pasan en la región de interés cuando desempeñan el papel de forrajero.

Condición a ciegas

Esta condición se empleó como línea base para determinar si las poblaciones de robots previamente evolucionadas estaban efectivamente empleando la luz azul para localizar la región de interés. Se empleó el mismo escena-

rio, parámetros y procedimientos que en la condición de luz encendida, pero con una diferencia: el anillo de LEDs azules de los robots que desempeñaron el papel de señalizador se encontraba apagado durante todo el tiempo que duraron las simulaciones. Al igual que en la prueba anterior, solo nos interesaba evaluar el tiempo que el robot que desempeña el papel de forrajero pasó dentro de la región de interés.

Resultados de las condiciones luz encendida y a ciegas

Para cada una de las poblaciones que realizaron ambas tareas, se realizó una prueba t de medidas repetidas comparando el número de ciclos normalizados que los robots pasaron dentro de la región de interés, cuando desempeñaron el rol de forrajero entre la condición “a ciegas” comparada con la condición de “luz encendida”. Para las poblaciones evolucionadas en el experimento 5, se encontraron diferencias significativas entre la cantidad de ciclos que los robots estuvieron dentro de la región de interés en la condición luz encendida ($M = 0.4071544, SD = 0.2867842$) y la cantidad de ciclos que estuvieron en la región de interés en la condición a ciegas ($M = 0.05834816, SD = 0.06505874$); $p < 0.01$.

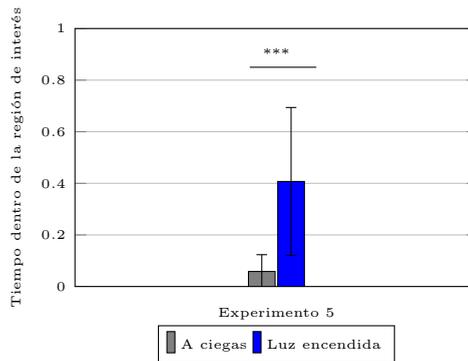


Figura 4.36: Diferencias entre las condiciones “luz encendida” y “a ciegas”, para los robots que solo perciben el color del otro robot, una prueba t de medidas repetidas fue realizada para ver las diferencias entre el número de ciclos que los robots pasan dentro de la región de interés para cada condición, los bigotes de la gráfica muestran la desviación estándar, *** $p < 0.01$.

Pruebas de altruismo						
Parentesco con el otro robot	1	0.8	0.6	0.4	0.2	0
Cantidad de comida	2					
	1.8					
	1.6					
	1.4					
	1.2					
	1					
Generaciones por grupo	36					
Individuos por generación	100					
Individuos por condición	3600					

Cuadro 4.28: Condiciones de prueba para determinar nivel de altruismo

Pruebas para determinar el nivel de altruismo

Una vez comprobado que los robots han aprendido que la luz azul es una señal fiable de comida, debemos determinar si han evolucionado la estrategia de señalar la comida y si, como sugiere la regla de Hamilton, esta estrategia tiene relación con el nivel de parentesco.

Para ello, utilizamos un diseño experimental 6×6 (6 niveles de parentesco con 6 diferentes niveles de comida en la región de interés) (ver Tabla 4.28), siendo cada uno de estos grupos evaluados utilizando 6 niveles de “falso parentesco” (ver Tabla 4.28).

Para generar este falso parentesco, modificamos el genoma del robot que realizaría la prueba en el porcentaje deseado. Por ejemplo, si necesitamos un parentesco de 0.8, mutamos el genoma de nuestro individuo en un 20 % y usamos a este robot mutado como el robot forrajero para el periodo de vida correspondiente al robot que queremos medir, utilizando el SOM para asignarle su color correspondiente.

Durante esta prueba, todos los robots evolucionados solo jugaron de señalizador. Dado que la característica primordial que deseamos cuantificar es el nivel de emisión de luz azul cuando el robot se encuentra en la región de interés, mientras que los robots que desempeñan el papel de forrajero fueron creados solo con el fin de evaluar la reacción de nuestra población ya evolucionada.

4.6.4. Generaciones a medir

Dado que las características de nuestro problema y el estudio del espacio de solución en el SOM parecían indicar que nuestras poblaciones no convergían en un solo punto del espacio de solución, decidimos evaluar el rendimiento de nuestras poblaciones en diversos momentos del proceso evolutivo en los que creíamos que podrían revelar información interesante.

Los grupos estuvieron conformados por 9 generaciones de nuestro algoritmo evolutivo que mostraban 4 diferentes características: las que mostraron mayor convergencia en el espacio de solución (alta agrupación), las que presentaban mayor diversidad (baja agrupación), las que mostraban mayor altruismo (alta emisión) y las que mostraban poco altruismo (baja emisión). Al haber 4 ejecuciones de nuestro algoritmo evolutivo y estar cada generación conformada por 100 individuos, esto nos daba un total de 36 puntos de medición por característica, para un total de 3600 individuos por grupo. De cada uno de estos grupos, cada robot cumple 20 veces con la función de señalizador para cada una de las condiciones experimentales. La tarea, entorno y los parámetros utilizados fueron los mismos que durante el proceso evolutivo.

Por su nivel de entropía

Para definir nuestros puntos de medición, usamos el criterio de agrupación de los fenotipos de nuestras poblaciones en el espacio de solución del problema, tal como se estableció en nuestro SOM.

Para evaluar el nivel de agrupación de nuestras poblaciones, utilizamos la entropía de Shannon como medida de comprensibilidad de la información. Esta ha sido utilizada en el campo de la biología para medir la diversidad presente en un ecosistema [Jost \(2006\)](#). La entropía de Shannon se define como:

$$H(X) = - \sum_{i=1}^n p(x_i) \log_b p(x_i) \quad (4.6)$$

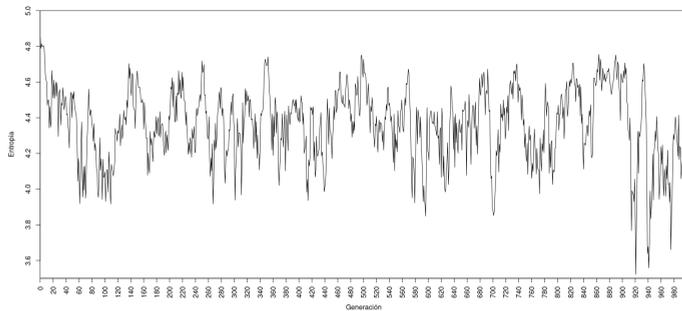
En nuestro caso el valor b es igual 2.

Como se puede observar en todas nuestras ejecuciones del algoritmo evolutivo, la entropía disminuye desde su posición inicial en la generación inicial, y posteriormente oscila aparentemente de forma errática durante las generaciones posteriores del algoritmo evolutivo. Esto implica que, aunque las poblaciones disminuyen su entropía al converger en soluciones a partir de su estado inicial de aleatoriedad, la variabilidad genética dentro de nuestra

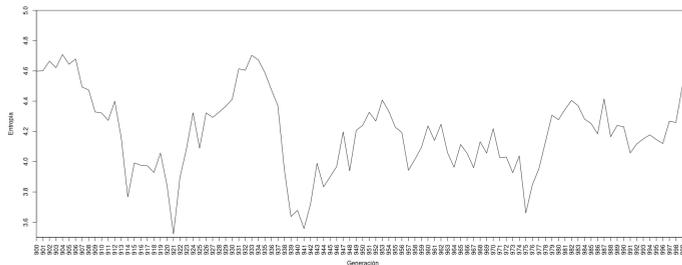
población a lo largo del tiempo aumenta y disminuye a partir de las presiones evolutivas creadas por las nuevas soluciones, en un proceso conocido como evolución open-ended.

No obstante, estos cambios no son tan bruscos como pareciera cuando examinamos las 1000 generaciones de las cuatro ejecuciones del algoritmo evolutivo, sino que se suavizan cuando hacemos un acercamiento y vemos cómo se comportan en un bloque de 100 generaciones. Esto es relevante porque nos indica el cambio gradual que se espera en las estrategias de nuestras poblaciones en una escala de tiempo evolutivo.

A continuación, se muestran las figuras que ilustran la entropía de Shannon de las dos primeras corridas del algoritmo evolutivo:

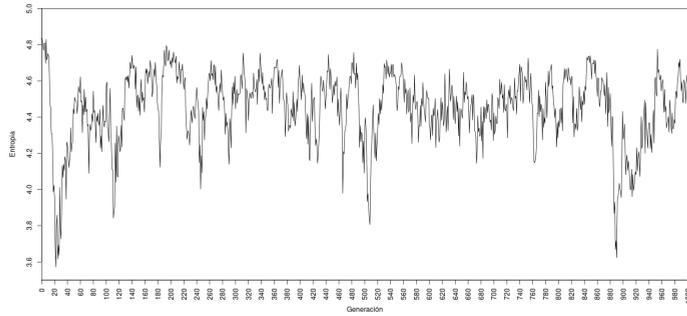


(a) 1000 generaciones

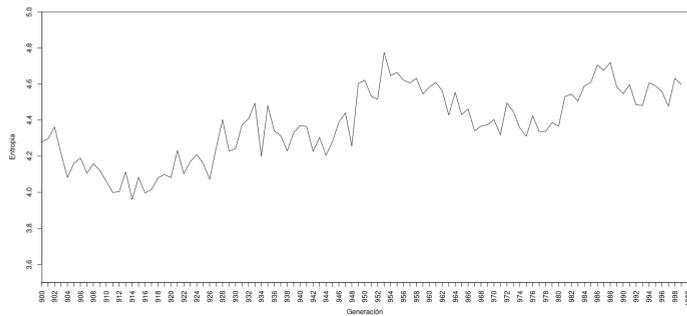


(b) Zoom a la entropía del último bloque

Figura 4.37: Entropía de Shannon de la corrida 1 del algoritmo evolutivo, en el eje de las y la cantidad de entropía promedio de cada generación

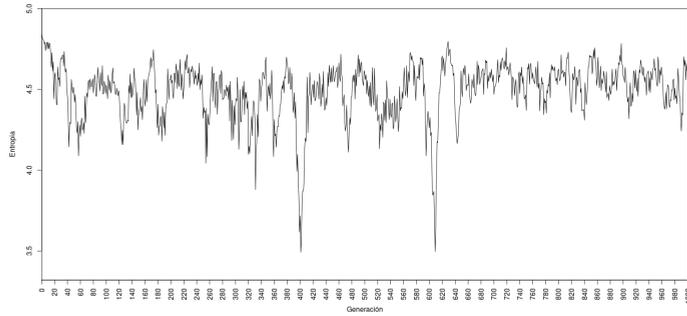


(a) 1000 generaciones

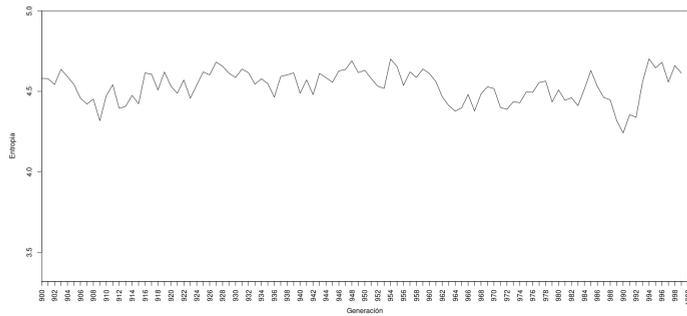


(b) Zoom a la entropía del último bloque

Figura 4.38: Entropía de Shannon de la corrida 2 del algoritmo evolutivo, en el eje de las y la cantidad de entropía promedio de cada generación

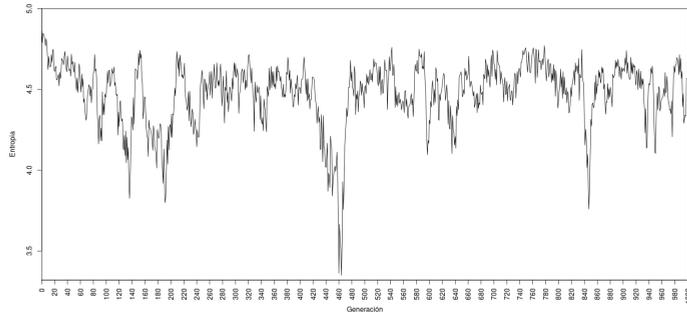


(a) 1000 generaciones

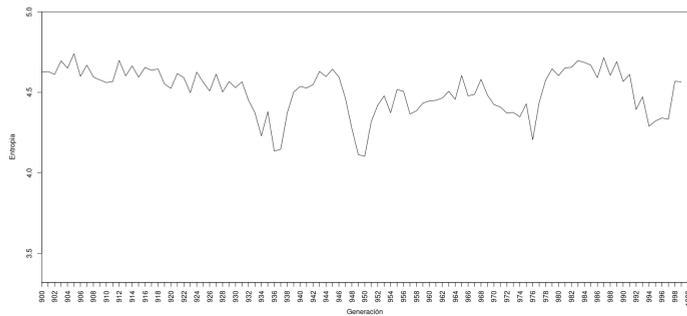


(b) Zoom a la entropía del último bloque

Figura 4.39: Entropía de Shannon de la corrida 3 del algoritmo evolutivo, en el eje de las x el número de generación y en el eje de las y la cantidad de entropía de cada generación



(a) 1000 generaciones



(b) Zoom a la entropía del último bloque

Figura 4.40: Entropía de Shannon de la corrida 4 del algoritmo evolutivo, en el eje de las y la cantidad de entropía promedio de cada generación

Alta agrupación (Baja entropía)

En primer lugar, evaluamos los puntos en los que nuestras poblaciones experimentaban un mayor nivel de agrupación en el espacio de solución. Estos puntos son relevantes porque, cuando la diversidad genética de nuestras poblaciones es baja, esto podría indicar que una o más soluciones producidas por el algoritmo evolutivo tienen un comportamiento lo suficientemente exitoso para dominar en mayor medida el acervo genético durante la evolución del algoritmo.

Sin embargo, debido a que este cambio en el nivel de entropía ocurre gradualmente entre una generación y otra de cada una de nuestras ejecuciones del algoritmo evolutivo, es probable que si simplemente tomáramos los 10 puntos con la entropía más baja, estos puntos de medición terminarían siendo generaciones contiguas. Esto no sería representativo de todo el proceso evolutivo, sino solo una fotografía del momento de más baja entropía de las 1000 generaciones.

Para evitar que todas nuestras mediciones se produjeran en puntos contiguos de las generaciones del algoritmo evolutivo, dividimos nuestras mil generaciones en diez bloques de cien generaciones. Descartamos el primer bloque para asegurarnos de que el algoritmo tuviera tiempo de evolucionar algún comportamiento, y luego buscamos la generación con la entropía más baja en cada uno de estos nueve bloques. Repetimos este proceso para cada una de las cuatro ejecuciones del algoritmo evolutivo, obteniendo un total de 36 puntos de medición considerados como puntos de alta agrupación.

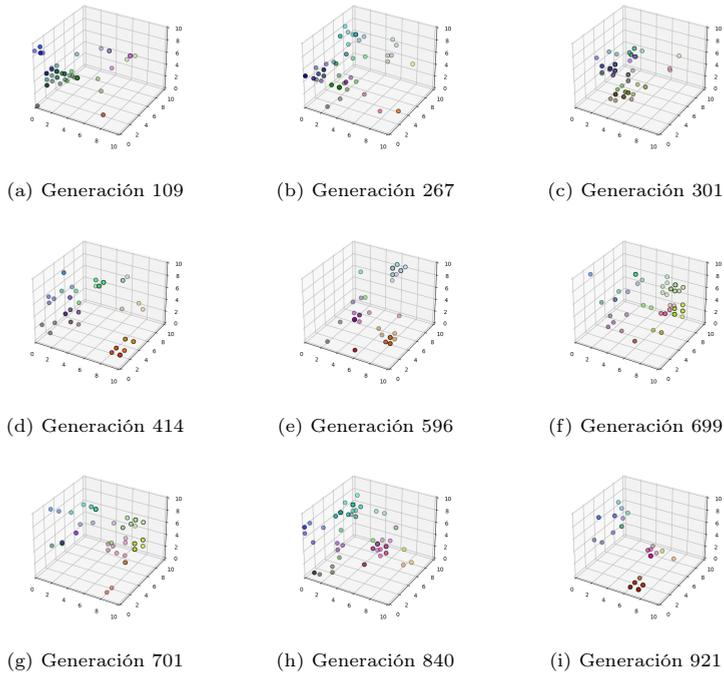


Figura 4.41: Alta agrupación

Baja agrupación (Alta entropía)

En segundo lugar, medimos los puntos en los que nuestras poblaciones tenían el menor nivel de agrupación en el espacio de solución. Estos puntos de medición resultan interesantes debido a que, dada la alta dispersión de los individuos dentro del espacio de solución, podríamos presumir que existe una mayor cantidad de diversidad genética y, por lo tanto, un mayor número de soluciones conviviendo simultáneamente en nuestras poblaciones.

Para identificar las generaciones con una entropía alta, empleamos el mismo procedimiento utilizado para determinar las generaciones de baja entropía. En primer lugar, medimos la entropía de Shannon (ver fórmula 4.6) y posteriormente dividimos las 100 generaciones de nuestro algoritmo evolutivo en 10 bloques de 10 generaciones. Descartamos el primer bloque para asegurarnos de que haya pasado suficiente tiempo para que alguna

conducta evolucione, y tomamos las generaciones con la entropía más alta de cada uno de los bloques. Este proceso se repitió en las cuatro ejecuciones de nuestro algoritmo evolutivo, dando como resultado un total de 36 puntos de medición.

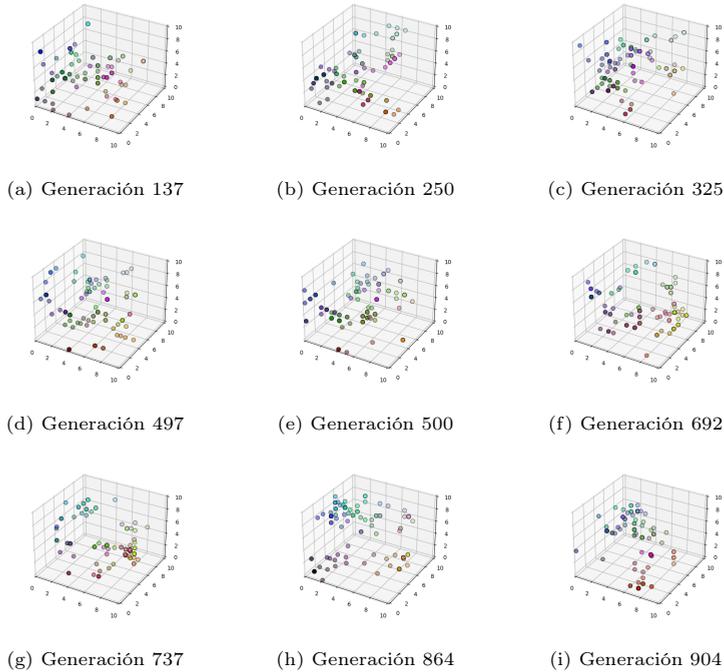


Figura 4.42: Baja agrupación

Alta emisión

En tercer lugar, decidimos medir los puntos en los que nuestras poblaciones tenían individuos con los niveles promedio más altos de emisión de luz azul en la región de interés. Estos puntos de medición son interesantes, ya que se trata de las generaciones que, al menos en su estado silvestre, muestran el mayor nivel de comportamiento altruista. Como podemos ver en la tabla 4.29, estas generaciones no se corresponden con las generaciones de más alta agrupación, lo que nos indica que, a pesar de haber diversas solu-

ciones conviviendo en dichas poblaciones, la conducta altruista se mantiene de forma elevada.

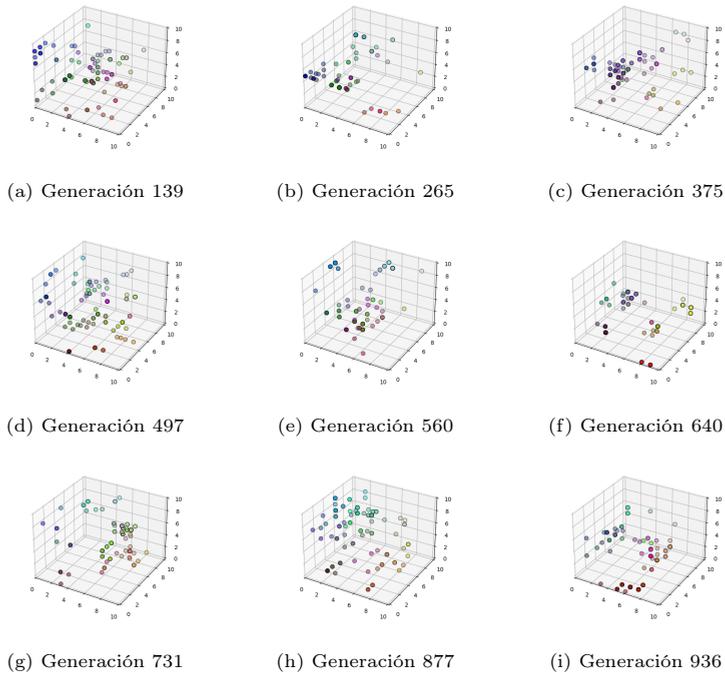


Figura 4.43: Alta emisión

Para seleccionar las generaciones con alta emisión, dividimos las 1000 generaciones de nuestro algoritmo evolutivo en 10 bloques de 100 generaciones cada uno. Descartamos el primer bloque para asegurarnos de que hubiera suficiente tiempo para la evolución de alguna conducta. Luego, seleccionamos la generación que tuviera el nivel más elevado de emisión para cada uno de los nueve bloques pertenecientes a cada una de las 4 ejecuciones de nuestro algoritmo evolutivo. Esto nos dio un total de 36 generaciones seleccionadas.

Baja emisión

Por último, medimos los puntos de nuestras poblaciones que tenían en promedio robots con niveles más bajos de emisión de luz azul en la región de interés. Es importante saber si en estas generaciones que se mostraron poco altruistas, la conducta de emitir luz azul se extingue por completo en la población o se mantiene en una parte de la población. Al igual que en el caso de las generaciones de alta emisión, estas generaciones no se corresponden ni con las de baja entropía ni, como pudiese llegar a pensarse, con las de alta entropía. Esto parece insinuar que esta bajada en la emisión de luz azul no se debe a la alta diversidad genética en determinada población ni a que el algoritmo haya convergido totalmente en la conducta de no emitir luz azul.

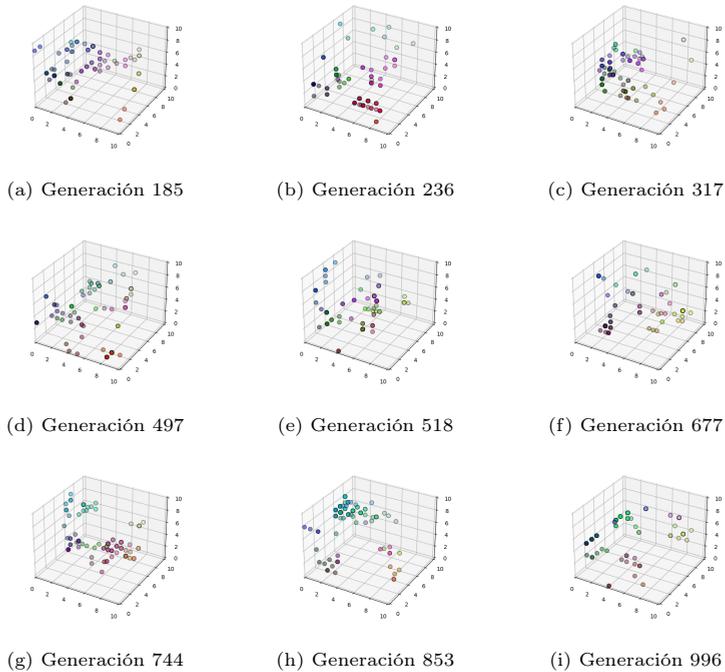


Figura 4.44: Baja emisión

Para seguir el mismo procedimiento, dividimos las generaciones de nuestro algoritmo evolutivo en 10 bloques de 100 generaciones cada uno. Descar-

Generaciones seleccionadas para realizar las pruebas									
Corrida 1	Generaciones								
Alta agrupación	109	267	301	414	596	699	701	840	921
Baja agrupación	137	250	352	497	500	692	737	864	904
Alta emisión	139	265	375	497	560	640	731	877	936
Baja Emisión	185	236	317	443	518	677	744	853	996
Corrida 2	Generaciones								
Alta agrupación	111	246	377	466	508	673	763	890	914
Baja agrupación	193	204	312	483	534	631	753	849	953
Alta emisión	117	277	366	405	546	632	783	800	947
Baja Emisión	135	251	305	421	504	616	754	828	999
Corrida 3	Generaciones								
Alta agrupación	126	254	399	401	595	609	777	840	990
Baja agrupación	173	225	379	463	571	629	719	897	994
Alta emisión	114	288	353	496	584	656	721	897	956
Baja Emisión	134	262	394	468	509	600	708	811	932
Corrida 4	Generaciones								
Alta agrupación	191	240	348	464	597	635	799	847	950
Baja agrupación	152	209	321	406	542	698	778	836	905
Alta emisión	136	221	383	427	534	654	764	853	992
Baja Emisión	120	295	329	472	564	641	799	807	969

Cuadro 4.29: En la tabla se muestran las 9 generaciones de cada una de las cuatro condiciones; alta agrupación, baja agrupación, alta emisión, baja emisión elegidas para realizar las pruebas

tamos el primer bloque para asegurarnos de que hubiera suficiente tiempo para la evolución de alguna conducta. Luego, calculamos el promedio del nivel de emisión que todos los robots tuvieron dentro de la región de interés para cada una de las generaciones, y seleccionamos de cada bloque aquellas que presentaban la menor emisión promedio.

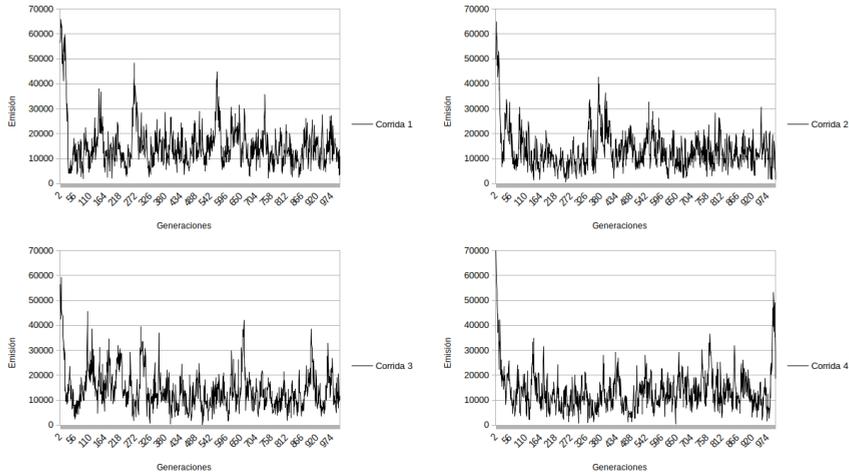


Figura 4.45: Emisión promedio que los robots de cada generación del experimento 5 tuvieron durante el proceso evolutivo, para los cuatro procesos evolutivos.

Resultados para las generaciones con baja agrupación

Al medir el 20% de los individuos más emisores de las generaciones con baja agrupación en cada uno de los bloques de las cuatro ejecuciones del algoritmo evolutivo (alta entropía), se observó que, en las 36 condiciones de prueba, el promedio de emisión de los individuos pertenecientes al 20% más emisor se mantuvo por encima del 49%. Esto indica que, a pesar de tratarse de las generaciones con una mayor variabilidad fenotípica, la conducta de emisión de luz azul en la región de interés se mantiene de manera significativa en al menos una parte importante de nuestras poblaciones.

Estos datos se corresponden con la existencia de una variedad de soluciones (fenotipos) coexistiendo simultáneamente en nuestra población, como lo demuestra la representación gráfica de nuestras poblaciones utilizando mapas autoorganizados y las diversas conductas que pueden observarse en la gráfica de violines, incluso en el 20% de los individuos más emisores de estas poblaciones. Es importante recordar que estamos midiendo el punto de mayor entropía en cada uno de los bloques de 100 generaciones en los que dividimos las poblaciones resultantes del proceso evolutivo. En este sentido, esta variabilidad genética y fenotípica que encontramos en nuestras poblaciones no es algo que haya surgido de manera puntual para luego extinguirse,

	Parentesco percibido					
	1	0.8	0.6	0.4	0.2	0
Emisión promedio	0.5178	0.5125	0.5078	0.5059	0.5035	0.5046

Cuadro 4.30: Emisión promedio en la región de interés cuando agrupamos por la condición de parentesco para las generaciones con baja agrupación

sino que aparece a lo largo de todo el proceso evolutivo. Como veremos más adelante, incluso en puntos de emisión con una mayor agrupación, lo cual sugiere un proceso de evolución de “open ending” donde no solo no se alcanza un óptimo global, sino que las diversas soluciones presentes en la población del algoritmo evolutivo compiten entre ellas, creando sus propias presiones selectivas que impiden que el algoritmo converja en un solo óptimo local o global.

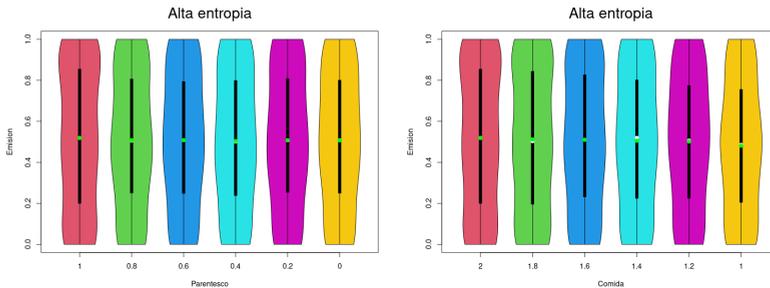


Figura 4.46: Gráfica de violines para el 20% de individuos más emisor de las generaciones menos agrupadas, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana

Por último, aunque el promedio de emisión se mantiene elevado, no parece haber una correlación clara entre la emisión y el nivel de parentesco o comida presentes en cada una de las condiciones de prueba. Esto se observa tanto al analizar a los individuos en cada una de las 36 condiciones, como al agrupar los resultados por comida o parentesco (ver tabla 4.48).

	Cantidad de comida					
	2	1.8	1.6	1.4	1.2	1
Emisión promedio	0.51	0.5133	0.5123	0.5115	0.5031	0.5018

Cuadro 4.31: Emisión promedio en la región de interés cuando agrupamos por la condición de comida para las generaciones con baja agrupación

Baja agrupación, 20 % de individuos más emisores experimento 5

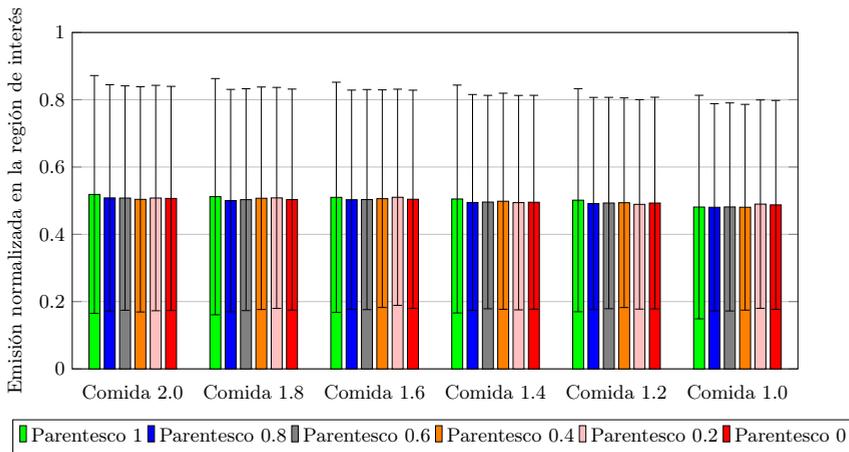


Figura 4.47: Diferencias de emisión de luz según el nivel de parentesco para el 20 % de los individuos más emisores para cada una de las 9 generaciones con alta entropía para las 4 poblaciones evolucionadas, en las 36 condiciones de prueba, los bigotes muestran la desviación estándar.

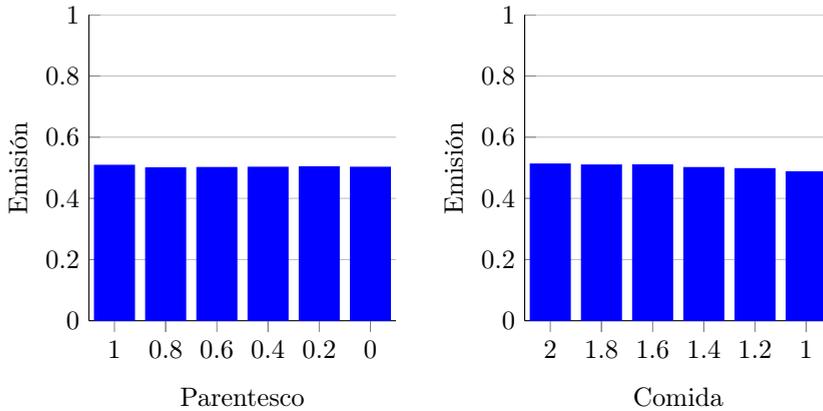


Figura 4.48: Promedio de emisión del 20% de los individuos más emisores para las 9 generaciones de baja agrupación de cada uno de las 4 ejecuciones del algoritmo evolutivo, agrupados según la cantidad de parentesco y la cantidad de comida en cada una de las 36 condiciones de prueba.

Resultados para las generaciones con alta agrupación

Al medir el 20% de los individuos más emisores de las generaciones con alta agrupación de las cuatro ejecuciones del algoritmo evolutivo (baja entropía), observamos resultados muy similares a los de las generaciones poco agrupadas. En las 36 condiciones de prueba, el promedio de emisión de los individuos pertenecientes al 20% más emisor se mantuvo igualmente por encima del 49%, pero sin experimentar un aumento significativo.

Como podemos ver en la gráfica de violines, tanto cuando agrupamos a los individuos por condición de parentesco como por condición de comida, existe una alta variabilidad en el nivel de emisión de luz azul dentro de la región de interés. Esto nos indica que, a pesar de tratarse de las generaciones donde hay una mayor agrupación y, por lo tanto, podríamos esperar una menor variabilidad fenotípica, ni la conducta de actuar altruistamente de forma indiscriminada, ni la de no emitir luz azul, logran dominar el acervo genético de nuestras poblaciones lo suficiente como para que las otras conductas se extingan.

Todo esto se confirma al observar las imágenes producidas al plotear a dichas poblaciones usando un SOM, las cuales muestran que las poblaciones nunca convergen en un mismo punto en el espacio de solución. Esto demuestra que, incluso en las poblaciones que presentan una menor variabilidad genética, existen diversas soluciones coexistiendo en el acervo genético,

	Parentesco percibido					
	1	0.8	0.6	0.4	0.2	0
Emisión promedio	0.5178	0.5125	0.5078	0.5059	0.5035	0.5046

Cuadro 4.32: Emisión promedio en la región de interés cuando agrupamos por la condición de parentesco para las generaciones con alta agrupación

e insinúa que debe existir alguna característica o subconjunto de nuestras poblaciones que evita que tanto la conducta de emitir luz siempre en la región de interés, a la que podríamos llamar “altruismo ingenuo”, como la de nunca emitir luz azul en la misma, se extingan por completo.

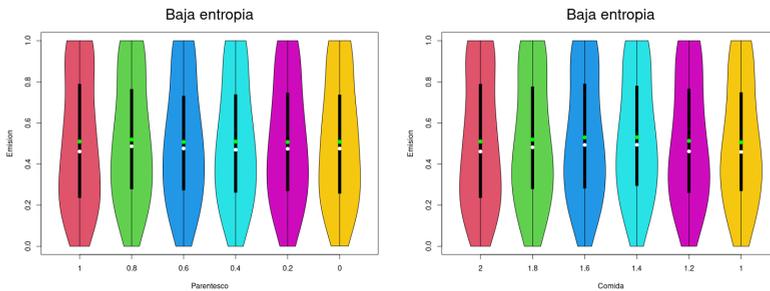


Figura 4.49: Gráfica de violines para el 20% de individuos más emisor de las generaciones más agrupadas, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana

Nuevamente, estos datos se alinean con la existencia de una variedad de soluciones (fenotipos) conviviendo simultáneamente en nuestra población, aun en las generaciones con menos variabilidad fenotípica. Sin embargo, al igual que en el caso de las poblaciones con baja agrupación, esta emisión no parece correlacionarse con el nivel de parentesco o comida presentes en cada una de las condiciones de prueba, tanto cuando lo vemos en cada una de 36 condiciones como cuando lo agrupamos por comida (tabla 4.33) o parentesco (tabla 4.32) (Gráfica4.51).

	Cantidad de comida					
	2	1.8	1.6	1.4	1.2	1
Emisión promedio	0.5088	0.5056	0.5060	0.4972	0.4936	0.4834

Cuadro 4.33: Emisión promedio en la región de interés cuando agrupamos por la condición de comida para las generaciones con alta agrupación

Alta agrupación , 20 % de individuos más emisores experimento 5

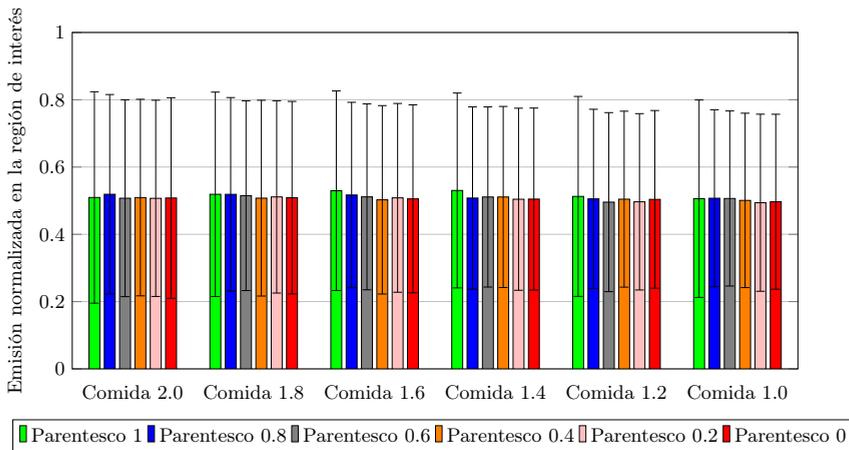


Figura 4.50: Diferencias de emisión de luz según el nivel de parentesco para el 20 % de individuos más emisores para cada una de las 9 generaciones con alta agrupación para las 4 poblaciones evolucionadas, en las 36 condiciones de prueba, los bigotes muestran la desviación estándar.

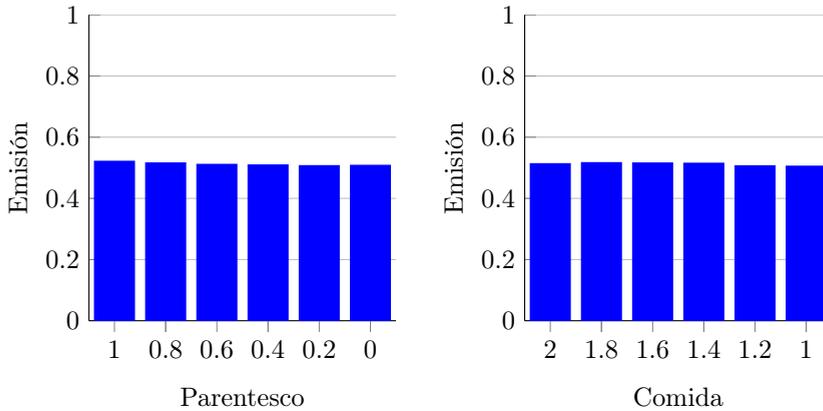


Figura 4.51: Promedio de emisión del 20% de los individuos más emisores para las 9 generaciones de alta agrupación de cada una de las 4 ejecuciones del algoritmo evolutivo, agrupados según la cantidad de parentesco y la cantidad de comida en cada una de las 36 condiciones de prueba.

Resultados para las generaciones con alta emisión

Cuando medimos el 20% de los individuos con una mayor emisión de las generaciones con alta emisión, observamos, como era de esperar, que presentan una emisión significativamente mayor en comparación con los otros puntos de medición. A través de las 36 condiciones de prueba (ver gráfica 4.54), el promedio de emisión de los individuos pertenecientes al 20% más emisor se mantuvo por encima del 79%, e incluso superó el 80% cuando los agrupamos tanto por nivel de parentesco (ver Tabla 4.34) como por cantidad de comida (ver Tabla 4.35) presente en el escenario.

No obstante, a diferencia de lo que podríamos anticipar según la regla de Hamilton, la gráfica de violines de estas poblaciones indica que la mayoría de los individuos más emisores de esta población tienen una emisión cercana a 1 en todas las condiciones de comida y parentesco. Al considerar la media y la mediana de estas condiciones, parece que el parentesco y la cantidad de comida tienen un efecto mínimo en el comportamiento de estos individuos. En general, muestran lo que podríamos catalogar como un altruismo ingenuo. Esto nos lleva a preguntarnos cómo es posible que esta conducta no solo no se extinga por completo del acervo genético, como la teoría podría sugerir para una población de este tipo, sino que persista y se propague en varias etapas de la evolución de nuestras poblaciones.

Esto resulta aún más problemático si consideramos que, aunque en estos

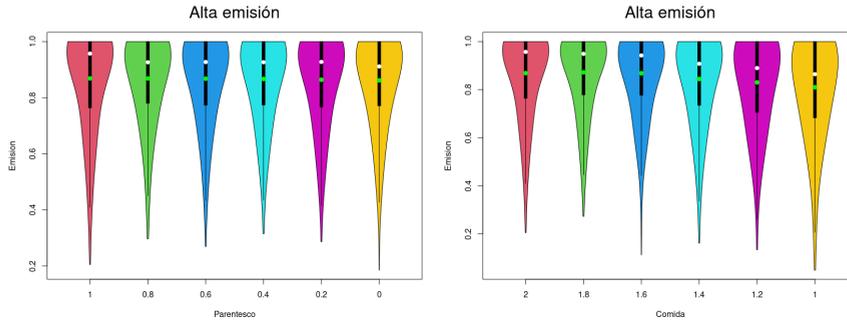


Figura 4.52: Gráfica de violines para el 20% de individuos más emisor de las generaciones más emisoras, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana

	Parentesco percibido					
	1	0.8	0.6	0.4	0.2	0
Emisión promedio	0.8449	0.8408	0.8383	0.8373	0.8356	0.8319

Cuadro 4.34: Emisión promedio en la región de interés cuando agrupamos por la condición de parentesco para las generaciones con alta emisión

puntos de medición la conducta de emitir luz azul en la región de interés se vuelve más común, al graficar dichas generaciones a través del SOM, podemos ver que no se converge a un solo punto en el espacio de solución. Además, aun dentro del 20% más emisor de nuestras poblaciones, podemos observar la presencia de individuos poco emisores en las gráficas de violines. Esto nos lleva a pensar que nuestra medición está pasando por alto o desechando a individuos que sirven de buffer entre aquellos que presentan la conducta de altruismo ingenuo y los no altruistas.

Por último, estos resultados, aunados a la composición de la población reflejada por el SOM, siguen fortaleciendo la teoría de que diversas soluciones se mantienen conviviendo en el acervo genético a lo largo de todo el proceso evolutivo.

	Cantidad de comida					
	2	1.8	1.6	1.4	1.2	1
Emisión promedio	0.8449	0.8408	0.8383	0.8373	0.8356	0.8319

Cuadro 4.35: Emisión promedio en la región de interés cuando agrupamos por la condición de comida para las generaciones con alta emisión

Alta emisión, 20% de individuos más emisores experimento 5

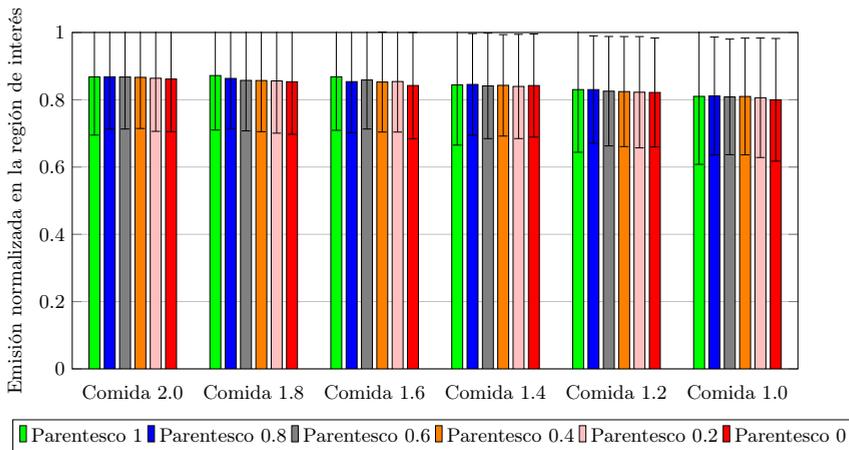


Figura 4.53: Diferencias de emisión de luz según el nivel de parentesco para el 20% de individuos más emisores para cada una de las 9 generaciones con alta entropía para las 4 poblaciones evolucionadas, en las 36 condiciones de prueba, los bigotes muestran la desviación estándar.

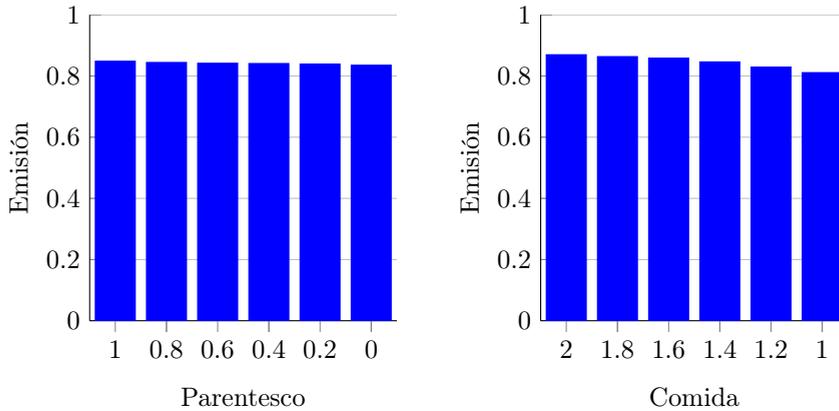


Figura 4.54: Promedio de emisión del 20% de los individuos más emisores para las 9 generaciones con más emisión de cada uno de las 4 ejecuciones del algoritmo evolutivo, agrupados según la cantidad de parentesco y la cantidad de comida en cada una de las 36 condiciones de prueba.

Resultados para las generaciones con baja emisión

Al medir el 20% de individuos más emisores de las generaciones con la menor emisión de luz azul en la región de interés, se observó una reducción importante en la emisión de luz. A través de las 36 condiciones de prueba, el promedio de emisión de los individuos pertenecientes al 20% más emisor se mantuvo por debajo del 27% y por encima del 26%, tanto cuando se agruparon por nivel de parentesco como por la cantidad de comida presente en el escenario.

Sin embargo, a pesar de que en estos puntos de medición la conducta de emitir luz azul es poco común tanto en la mayoría de la población como en el 20% de individuos más emisores, como se puede ver en la gráfica de violines, dicha conducta no se extingue totalmente, habiendo también en estos puntos de medición individuos que exhiben un altruismo ingenuo.

Además, al plotear las poblaciones en el SOM (véase gráfica 4.44), se puede observar que en ninguna de las generaciones medidas el algoritmo converge en un mismo espacio de solución. Esto apoya nuestra teoría de que existen múltiples soluciones conviviendo en las poblaciones de nuestro algoritmo evolutivo, y específicamente en la población con un promedio bajo de emisión.

Al igual que en el caso de las generaciones con alta emisión, el hecho de que la emisión de luz azul en el 20% individuos con más alta emisión de

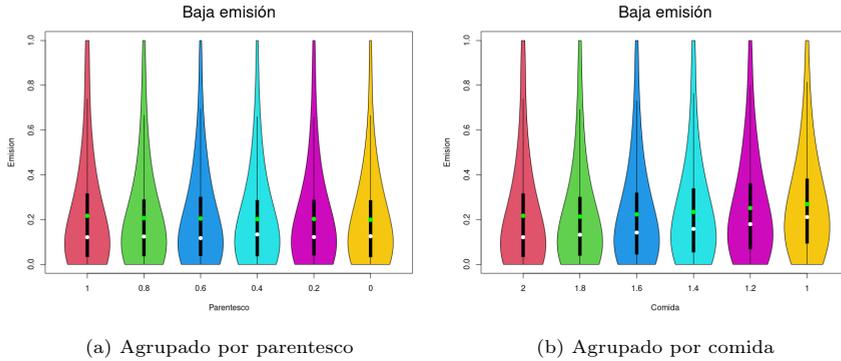


Figura 4.55: Gráfica de violines para el 20% de individuos más emisores de las generaciones con menor emisión de luz azul en la región de interés. El punto blanco representa el promedio de emisión y el verde la mediana.

	Parentesco percibido					
	1	0.8	0.6	0.4	0.2	0
Emisión promedio	0.23475	0.2263	0.2222	0.2217	0.2246	0.22045

Cuadro 4.36: Emisión promedio en la región de interés cuando agrupamos por la condición de parentesco para las generaciones con baja emisión

estas generaciones, no correlaciones con una mayor cantidad de parentesco percibido o comida en la región de interés, hace que nos preguntemos ¿Qué es lo que evita que esta conducta no se extinga por completo del acervo genético aun en las generaciones más egoístas? Pues sabemos por la literatura que cuando se ha intentado evolucionar conductas altruistas en poblaciones heterogéneas con selección individual, que las poblaciones convergen en la conducta de no emitir luz. Nuevamente, teorizamos que en estas poblaciones debe de existir un subconjunto que tenga una conducta evolutivamente estable capaz de impedir la extinción total de los altruistas ingenuos y que, por lo tanto, este subconjunto de la población debería estar exhibiendo una conducta parecida a la predicha por la regla de Hamilton.

	Cantidad de comida					
	2	1.8	1.6	1.4	1.2	1
Emisión promedio	0.2056	0.2061	0.2137	0.2266	0.2395	0.2584

Cuadro 4.37: Emisión promedio en la región de interés cuando agrupamos por la condición de comida para las generaciones con baja emisión

Baja emisión, 20% de individuos más emisores experimento 5

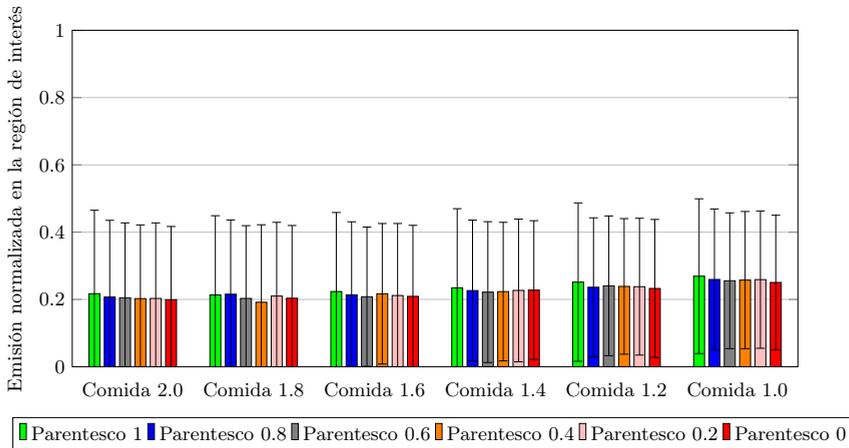


Figura 4.56: Diferencias de emisión de luz según el nivel de parentesco para el 20% de individuos más emisores para cada una de las 9 generaciones con baja emisión para las 4 poblaciones evolucionadas, en las 36 condiciones de prueba, los bigotes muestran la desviación estándar.

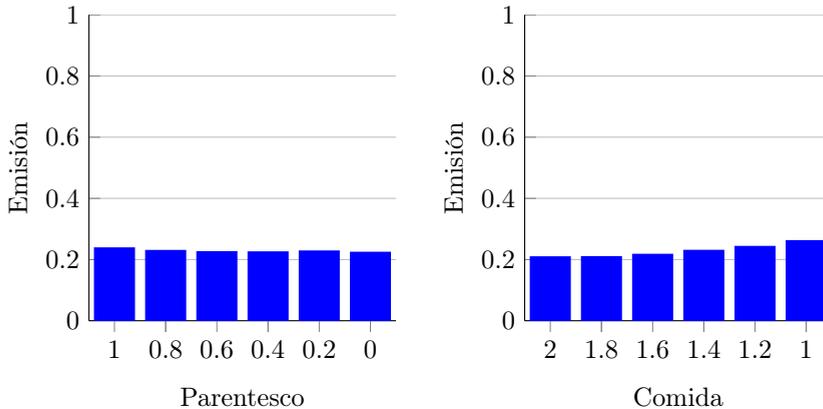


Figura 4.57: Promedio de emisión del 20% de los individuos más emisores para las 9 generaciones. Menos emisoras de cada una de las 4 ejecuciones del algoritmo evolutivo, agrupados según la cantidad de parentesco y la cantidad de comida en cada una de las 36 condiciones de prueba.

4.6.5. Búsqueda de individuos con comportamiento cercano a la regla de Hamilton en el experimento 3

En el experimento 3, continuamos nuestra búsqueda de individuos que presentaran un comportamiento cercano a la regla de Hamilton. Esta teoría sugiere que en individuos relacionados, la emisión de señales que informan sobre la presencia de recursos (como la luz azul en nuestro experimento) aumentará en relación con la cantidad de recursos disponibles y el grado de parentesco percibido. Debido a la falta de convergencia de nuestras poblaciones en un solo punto del espacio de solución en el experimento anterior, y la presencia de individuos que emitían indiscriminadamente mientras otros no emitían bajo ninguna condición, era difícil determinar cuáles eran las causas que mantenían la conducta de emitir luz en las poblaciones. Por ello, queríamos buscar individuos que mostraran un comportamiento similar al predicho por la regla de Hamilton, para poder entender mejor cómo se mantenía la conducta altruista en nuestras poblaciones.

Para llevar a cabo esta búsqueda, seguimos los mismos pasos que en el experimento anterior. En primer lugar, normalizamos la emisión de luz de cada uno de los robots entre cero y uno, utilizando los valores de E_{min} (emisión más baja) y E_{max} (emisión más alta) para cada individuo. Esto

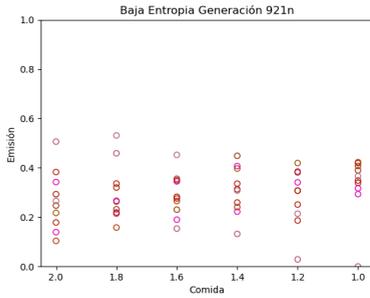
nos permitió medir el efecto de la discriminación por parentesco en la emisión de luz azul sin sesgar los resultados hacia individuos con emisiones más altas o más bajas.

Luego, asumimos que la emisión idealizada para cada una de las 36 condiciones de prueba mostraría un incremento lineal, así que la calculamos multiplicando el parentesco presente en cada una de las condiciones experimentales por la cantidad de comida presente en la región de interés y dividiendo dicho resultado entre 2 (**Véase la fórmula 4.4**).

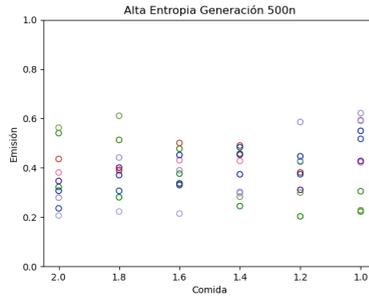
Posteriormente, medimos la distancia absoluta de cada uno de los 20 resultados que los robots tuvieron en cada una de las respectivas 36 condiciones de prueba con respecto a la emisión idealizada, y hicimos la sumatoria de esta distancia para cada individuo. Finalmente, seleccionamos a los 10 individuos que más se acercaban a lo predicho por la regla de Hamilton, con el objetivo de analizar más a fondo su conducta y entender mejor cómo se mantenía la conducta altruista en nuestras poblaciones.

Este proceso se realizó para todos los puntos de medición; alta entropía, baja entropía, alta emisión, baja emisión. Con un total de 36 puntos para cada tipo de medición (9 puntos de medición por corrida) para un total de 360 individuos por grupo.

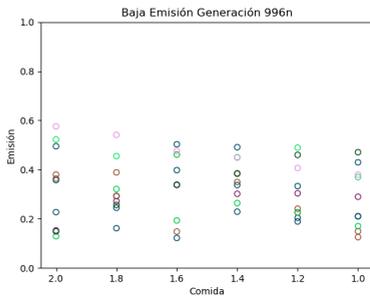
En las figuras 4.58 y 4.59 podemos ver los 10 robots que más se ajustan a esta regla de una de las generaciones en una de las cuatro ejecuciones del algoritmo evolutivo, para cada uno de los puntos de medición, tanto cuando agrupamos el desempeño de cada robot por parentesco figura 4.59, como cuando agrupamos por cantidad de comida en la región de interés 4.58.



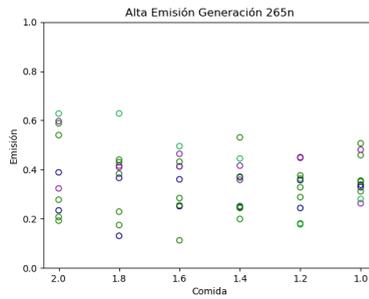
(a) Baja entropía (generación 921)



(b) Alta entropía (generación 500)

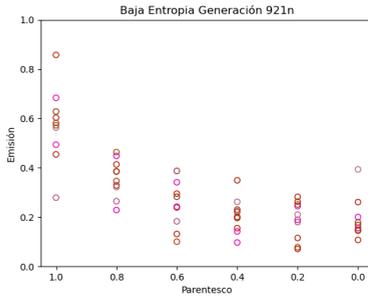


(c) Baja emisión (Generación 996)

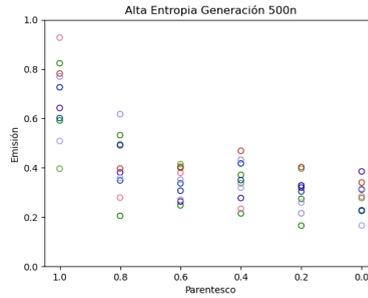


(d) Alta emisión (generación 265)

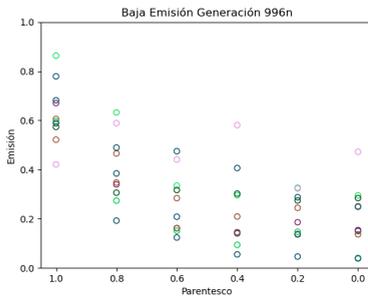
Figura 4.58: Gráfica del promedio de emisión para cada una de las condiciones de comida, pertenecientes a los diez individuos que mejor se ajustan a la regla de Hamilton para una de las generaciones con baja entropía, alta entropía, baja emisión y alta emisión, en la corrida 3 del algoritmo evolutivo, el color de cada punto es igual al producido por el fenotipo del robot que llevo a cabo la tarea.



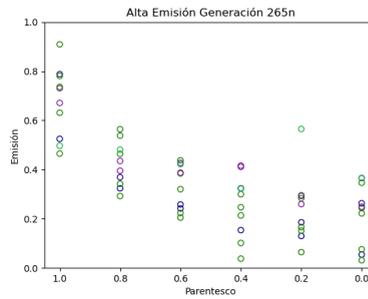
(a) Baja entropía (generación 921)



(b) Alta entropía (generación 500)



(c) Baja emisión (Generación 996)



(d) Alta emisión (generación 265)

Figura 4.59: Gráfica del promedio de emisión para cada una de las condiciones de emisión, pertenecientes a los diez individuos que mejor se ajustan a la regla de Hamilton para una de las generaciones con baja entropía, alta entropía, baja emisión y alta emisión, en la corrida 3 del algoritmo evolutivo, el color de cada punto es igual al producido por el fenotipo del robot que llevo a cabo la tarea.

4.6.6. Resultados para las generaciones con alta agrupación (baja entropía)

Al medir el desempeño del 10% de los individuos que mejor se ajustan a la emisión idealizada según la regla de Hamilton de cada una de las generaciones con alta agrupación (un total de 360 individuos), se observa que los individuos que mejor se ajustan a la emisión idealizada presentan, en promedio, una clara preferencia por emitir una mayor cantidad de luz azul cuando el parentesco entre ellos aumenta, tanto en las 36 condiciones (6 niveles de parentesco por 6 niveles de comida) como cuando se agrupan a los individuos solo por la condición de parentesco. Este fenómeno se presenta en las 4 ejecuciones del algoritmo evolutivo. Sin embargo, en el caso de la presencia de comida, no hay diferencias significativas, incluso cuando se buscan específicamente a los individuos que se ajustan a este comportamiento.

Resultados estadísticos

Dado que solo estábamos interesados en analizar el comportamiento de los robots que muestran una conducta altruista (emitir luz dentro de la región de interés) y si esta emisión se relaciona con el nivel de parentesco percibido por el robot, para fines del análisis estadístico solo utilizamos el 10% que mejor se ajustaron a la regla de Hamilton en cada grupo a lo largo de las 6 condiciones de parentesco para la cantidad de comida 2.0. Para dicho análisis, utilizamos una prueba ANOVA de medidas repetidas de una vía para cada grupo.

El ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 159$, $p < 0.05$. Es importante tener en cuenta que los valores F y p que se muestran corresponden al efecto del parentesco y no al modelo completo. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo evolucionado con 2.0 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas ($p < 0.05$) entre todas las condiciones (ver **tabla 4.5**), con las excepciones de la comparación entre el grupo 0.4 y 0.2 ($p = 0.06$) y entre 0.2 y 0 ($p = 1$).

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	**		
0.2	***	***	***	NS	
0	***	***	***	***	NS

Cuadro 4.38: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 2.0 , ** $p \leq 0.05$, *** $p \leq 0.01$

En las pruebas con una cantidad de comida de 1.8, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 161$, $p < 0.05$. Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Para comparar el grupo evolucionado con 1.8 unidades de comida bajo todas las condiciones de parentesco, se utilizó una prueba *t* de múltiples comparaciones y una vía con corrección de Bonferroni. Se encontraron diferencias significativas ($p < 0.05$) entre todas las condiciones, excepto en la comparación entre los grupos 0.4 y 0.2 ($p = 1$) y entre los grupos 0.2 y 0 ($p = 1$) (ver **tabla 4.39**).

Es importante tener en cuenta que los valores *F* y *p* que se muestran corresponden al efecto del parentesco y no al modelo completo. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

En las pruebas con 1.6 unidades de comida, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 153$, $p < 0.05$. Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	NS	
0	***	***	***	**	NS

Cuadro 4.39: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 1.8 , ** $p \leq 0.05$, *** $p \leq 0.01$

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	***		
0.2	***	***	***	NS	
0	***	***	***	NS	NS

Cuadro 4.40: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.6, ** $p \leq 0.05$, *** $p \leq 0.01$

Para comparar el grupo en las pruebas con 1.6 unidades de comida bajo todas las condiciones de parentesco, se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni. Se encontraron diferencias significativas ($p < 0.05$) entre todas las condiciones (ver **tabla 4.40**), excepto en la comparación entre los grupos 0.4 y 0.2 ($p = 1$), 0.4 y 0 ($p = 0.30$), y 0.2 y 0 ($p = 1$).

Es importante tener en cuenta que los valores F y p que se muestran corresponden al efecto del parentesco y no al modelo completo. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

En las pruebas con 1.4 unidades de comida, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 162$, $p < 0.05$. Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Para comparar el grupo en las pruebas con 1.4 unidades de comida bajo todas las condiciones de parentesco, se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni. Se encontraron diferencias significativas ($p < 0.05$) entre todas las condiciones, excepto en la comparación entre los grupos 0.6 y 0.4 ($p = 0.285$), 0.4 y 0.2 ($p = 0.892$), y 0.2 y 0 ($p = 1$) (ver **tabla 4.41**).

En las pruebas con comida 1.2, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 71$, $p < 0.05$. Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Para comparar el grupo en las pruebas con 1.2 unidades de comida bajo todas las condiciones de parentesco, se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni. Se encontraron diferencias significativas ($p < 0.05$) entre todas las condiciones, excepto en la

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	NS	
0	***	***	***	***	NS

Cuadro 4.41: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.4, ** $p \leq 0.05$, *** $p \leq 0.01$

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	**	
0	***	***	**	NS	NS

Cuadro 4.42: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.2, ** $p \leq 0.05$, *** $p \leq 0.01$

comparación entre los grupos 0.6 y 0.4 ($p = 1$), 0.4 y 0 ($p = 1$), y 0.2 y 0 ($p = 1$) (ver **tabla 4.42**).

En las pruebas con comida 1.0, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 132$, $p < 0.05$. Se realizó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Para comparar el grupo en las pruebas con 1.0 unidades de comida bajo todas las condiciones de parentesco, se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni. Se encontraron diferencias significativas ($p < 0.05$) entre todas las condiciones (ver **tabla 4.43**), excepto en la comparación entre los grupos 0.6 y 0.4 ($p = 0.3$), 0.4 y 2 ($p = 0.3$), 0.4 y 0 ($p = 0.7$), y 0.2 y 0 ($p = 1$).

Los resultados estadísticos de las pruebas realizadas en los puntos de alta agrupación en la evolución de nuestro algoritmo evolutivo nos muestran que en esos puntos existe un mecanismo de discriminación por parentesco.

Este mecanismo favorece claramente a los individuos que son del mismo color o similar que el individuo que realiza la tarea de emitir luz azul en la región de interés; como podemos ver en los resultados estadísticos este mecanismo se vuelve menos preciso cuando se trata de dar un trato diferen-

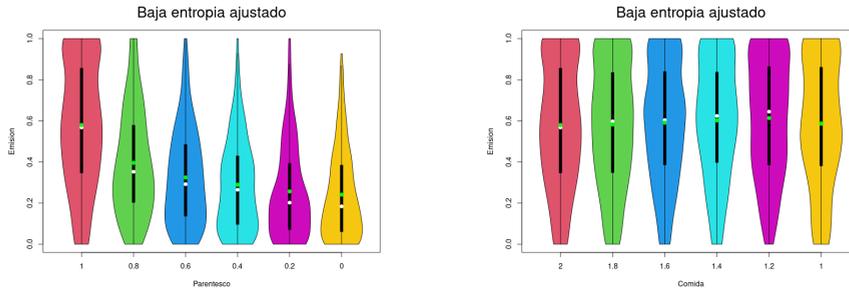
Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	NS	
0	***	***	**	NS	NS

Cuadro 4.43: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.0, ** $p \leq 0.05$, *** $p \leq 0.01$

ciado a dos individuos con un parentesco menor a 0.6, lo cual tiene sentido, ya que la única pista que los individuos tienen para realizar esta tarea es el color del otro individuo y resulta más fácil evolucionar una conducta que distinga más precisamente entre individuos con alto grado de parentesco (Parentesco 1 y 0.8) e individuos con bajo grado de parentesco (menor a 0.6), que un mecanismo que sea preciso para cada nivel de parentesco. Es importante tener en cuenta que estos resultados pueden verse influenciados por el hecho de que, aunque no hay una convergencia total en el algoritmo evolutivo, el parentesco entre los individuos siempre aumenta por encima de la aleatoriedad presente en las primeras generaciones. Esto hace que sea poco probable que los individuos encuentren consistentemente individuos con parentescos extremadamente bajos en el transcurso de su vida, lo que significa que no necesitan que el mecanismo de discriminación por parentesco sea tan preciso en esas situaciones.

Además, es interesante destacar que, aunque las generaciones en las que los individuos están más agrupados en el espacio, cuando se analiza el 20% de la población que más emite, no se observan diferencias significativas en el nivel de emisión en las distintas condiciones de parentesco. A esta conducta se le llama **altruismo ingenuo**. Sin embargo, cuando se buscan los individuos que mejor se ajustan a la regla de Hamilton, se encuentra que para este conjunto de individuos emerge el comportamiento de discriminación por parentesco.

Es importante destacar la existencia de este grupo de individuos, ya que nos permite explicar cómo se manifiesta el altruismo ingenuo en el comportamiento del 20% de los individuos más altruistas en poblaciones con baja entropía, y cómo se mantiene en estas poblaciones. A pesar de que existen individuos con un comportamiento egoísta capaces de encontrar la región de interés utilizando su emisión de luz azul, lo que teóricamente debería conducir a su extinción, la presencia de este grupo de individuos altruistas evita que esto suceda. Para confirmar que esto es lo que ocurre, deberíamos



(a) Gráfica de violines para el 10% de individuos que mejor se ajustan a la emisión idealizada dentro de las poblaciones más agrupadas, tanto cuando las agrupamos por nivel de parentesco presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana

(b) Gráfica de violines para el 10% de individuos que mejor se ajustan a la emisión idealizada dentro de las poblaciones más agrupadas, tanto cuando las agrupamos por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana

Figura 4.60: Subfiguras de las gráficas de violines para el 10% de individuos que mejor se ajustan a la emisión idealizada dentro de las poblaciones más agrupadas

encontrar individuos con un comportamiento similar en los demás puntos de medición; alta entropía, alta emisión y, sobre todo, en los puntos de baja emisión.

Por otra parte, el hecho de que este mismo fenómeno no se presente en relación con la variable alimento puede explicarse por el hecho de que la cantidad de comida cambiaba aleatoriamente en cada uno de los periodos de vida de cada robot. Esto pudo haber generado un comportamiento generalista ante todas las condiciones en lugar de uno específico para cada una de ellas. Además, muestra que a pesar de que estamos buscando a los individuos que más se ajustan a ese comportamiento, al no existir en nuestro acervo genético, dicho comportamiento no se refleja en nuestros resultados. Esto también nos confirma que el hecho de encontrar un comportamiento de emitir mayor cantidad de luz en relación con el parentesco para un subconjunto de la población no es simplemente el resultado de haber buscado a los individuos que mejor se ajustan a dicho comportamiento, sino que debe haber evolucionado como un mecanismo que proporcionaba a dichos individuos una ventaja evolutiva.

Baja entropía experimento 5

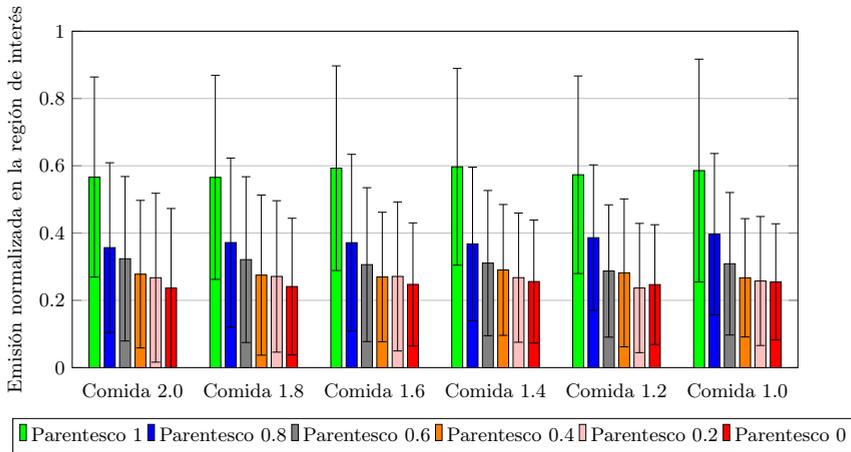


Figura 4.61: Diferencias de emisión de luz según el nivel de parentesco para los 10 individuos con emisión normalizada que más se ajustan a la regla de Hamilton en cada una de las 10 generaciones con baja entropía para las 4 poblaciones evolucionadas, en las 36 condiciones de prueba, los bigotes muestran la desviación estándar.

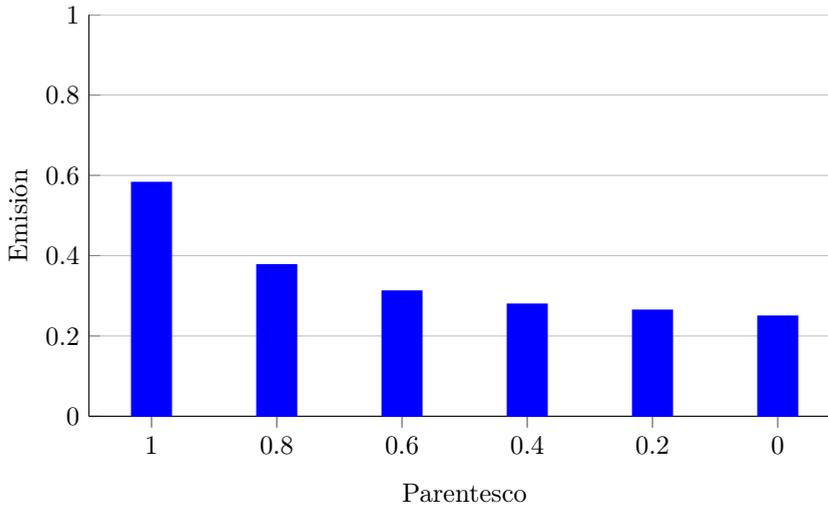


Figura 4.62: Promedio de emisión de los individuos que mejor se ajustan a la emisión idealizada para las 9 generaciones más agrupadas de cada una de las 4 ejecuciones del algoritmo evolutivo, agrupadas según la cantidad de parentesco presente en cada una de las 36 condiciones de prueba.

4.6.7. Resultados para las generaciones con baja agrupación (alta entropía)

En esta condición, se midió el desempeño del 10% de los individuos que mejor se ajustaban a la emisión idealizada según la regla de Hamilton en cada una de las generaciones con baja agrupación (9 puntos de medición para cada una de las 4 ejecuciones del algoritmo evolutivo).

Resultados estadísticos

Para el análisis estadístico, al igual que en las condiciones de alta agrupación, solo se utilizó el 10% de los individuos que mejor se ajustaban a la regla de Hamilton en cada grupo a través de las 6 condiciones de parentesco para las generaciones que mostraban alta entropía. Como en el caso anterior, se utilizó un ANOVA de medidas repetidas de una vía para cada grupo.

En las pruebas con comida 2.0, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 164$, $p < 0.05$. Además, se aplicó

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	NS	
0	***	***	**	NS	NS

Cuadro 4.44: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida 2*, ** $p \leq 0.05$, *** $p \leq 0.01$

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	**		
0.2	***	***	**	NS	
0	***	***	***	NS	NS

Cuadro 4.45: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida 1.8*, ** $p \leq 0.05$, *** $p \leq 0.01$

una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 2.0 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones, excepto por las condiciones 0.6 y 0.4 ($p = 0.801$), 0.4 y 0.2 ($p = 0.82$), 0.4 y 0 ($p = 0.108$), y 0.2 y 0 ($p = 1$) (**tabla 4.44**).

En las pruebas con comida 1.8, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 164$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.8 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones, excepto por las condiciones 0.4 y 0.2 ($p = 1$), 0.4 y 0 ($p = 1$), y 0.2 y 0 ($p = 1$) (**tabla 4.45**).

En las pruebas con comida 1.6, el ANOVA de medidas repetidas reveló

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	**	NS	
0	***	***	***	NS	NS

Cuadro 4.46: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.6 , ** $p \leq 0.05$, *** $p \leq 0.01$

un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5,1800) = 161$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.6 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones, excepto por las condiciones 0.6 y 0.4 ($p = 0.06$), 0.4 y 0.2 ($p = 1$), 0.4 y 0 ($p = 0.51$), y 0.2 y 0 ($p = 1$) (**tabla 4.46**).

En las pruebas con comida 1.4, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5,1800) = 173$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.4 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones (**tabla 4.47**), excepto por las condiciones 0.8 y 0.6 ($p = 0.219$), 0.4 y 0.2 ($p = 0.851$), 0.4 y 0 ($p = 1$), y 0.2 y 0 ($p = 1$).

En las pruebas con comida 1.2, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5,1800) = 159$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.2 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones (**tabla 4.48**), excepto

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	NS			
0.4	***	***	***		
0.2	***	***	**	NS	
0	***	***	***	NS	NS

Cuadro 4.47: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 1.4 , ** $p \leq 0.05$, *** $p \leq 0.01$

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	***	
0	***	***	NS	NS	NS

Cuadro 4.48: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 1.2 , ** $p \leq 0.05$, *** $p \leq 0.01$

por las condiciones 0.6 y 0.4 ($p = 1$), 0.6 y 0 ($p = 0.07$), 0.4 y 0 ($p = 0.279$), y 0.2 y 0 ($p = 1$).

En las pruebas con comida 1.0, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 141$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba *t* de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.0 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones (**tabla 4.49**), excepto por las condiciones 0.6 y 0.4 ($p = 1$), 0.6 y 0.2 ($p = 1$), 0.6 y 0 ($p = 0.07$), 0.4 y 0.2 ($p = 1$), 0.4 y 0 ($p = 0.67$) y 0.2 y 0 ($p = 0.43$).

En los resultados de nuestras pruebas estadísticas, podemos observar un fenómeno similar al que ocurre en la condición de alta agrupación. Los individuos que mejor se ajustan a la emisión idealizada presentan una clara preferencia por emitir en promedio una mayor cantidad de luz azul cuando el parentesco entre ellos aumenta. Sin embargo, esta conducta es menos precisa y no suele haber diferencias significativas cuando se compara la conducta que el robot muestra entre dos condiciones donde el parentesco es menor

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	NS	NS	
0	***	***	NS	NS	NS

Cuadro 4.49: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.0 , ** $p \leq 0.05$, *** $p \leq 0.01$

a 0.6. Esto puede explicarse de la misma manera que lo hicimos para los puntos de medición de baja entropía. Dado que el mecanismo evolucionado se centra en reconocer a los individuos con un alto nivel de parentesco y que las poblaciones, aunque no convergen en una única solución, sí aumentan el parentesco más allá de la aleatoriedad inicial del algoritmo, no es necesario y quizá tampoco útil evolucionar un comportamiento preciso para distinguir entre dos individuos ambos con bajo parentesco. En cambio, basta con evolucionar un mecanismo que favorezca a los individuos con un parentesco de 1 y 0.8, y compararlos con todos los demás con relativa precisión.

La aparición de una conducta similar en los puntos de alta entropía, junto con su presencia en poblaciones diversas y convergentes, indica que este comportamiento es evolutivamente estable en una amplia variedad de condiciones. En otras palabras, no importa cuán diversas sean las poblaciones o cuánto hayan convergido hacia un punto en el espacio de solución, este comportamiento no desaparecerá del acervo genético. Esto sugiere que es un comportamiento robusto y adaptativo que se mantiene en poblaciones evolucionadas bajo diferentes condiciones.

Sin embargo, al igual que en el caso de las poblaciones con alta agrupación, el comportamiento de emisión de luz no parece aumentar como lo predice la regla de Hamilton con un incremento en la cantidad de comida presente en el entorno. Esto sugiere que nuestra población desarrolló una conducta generalista ante la cantidad de comida presente en el entorno, probablemente debido a la gran variabilidad de la misma a lo largo de la vida de cada robot. Además, la ausencia de esta conducta en estos dos puntos de medición sugiere que no evolucionó en ninguna de nuestras poblaciones. Esto es sorprendente, ya que al tratarse de los puntos de mayor variabilidad genética, debería ser más fácil detectar si evolucionaron alguna vez. En el improbable caso de que hayan evolucionado, no fueron capaces de mantenerse en el acervo genético, probablemente porque una conducta generalista con la capacidad de realizar discriminación por parentesco resultaba más

favorable bajo estas condiciones evolutivas.

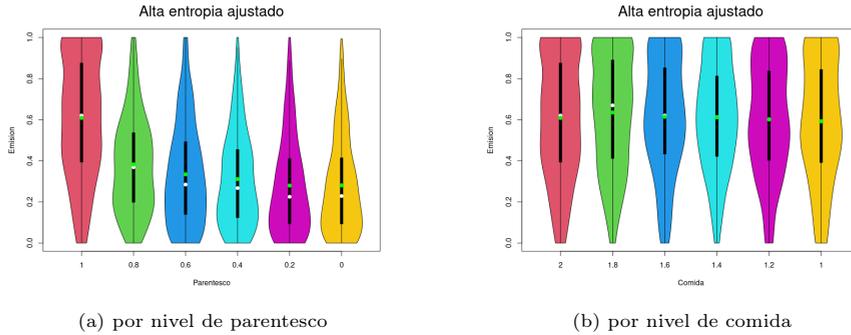


Figura 4.63: Gráficas de violines para el 10% de individuos que mejor se ajustan a la emisión idealizada de las generaciones menos agrupadas, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo. El punto blanco representa el promedio de emisión y el verde la mediana.

Alta entropía experimento 5

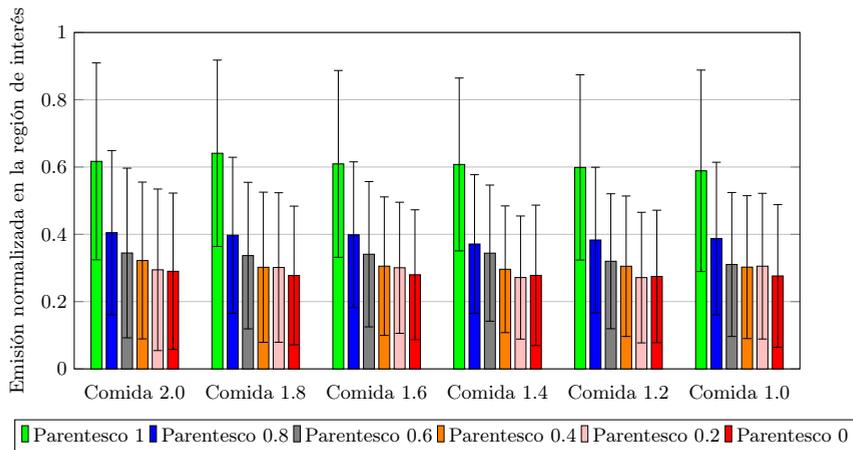


Figura 4.64: Diferencias de emisión de luz según el nivel de parentesco para los 10 individuos con emisión normalizada que más se ajustan a la regla de Hamilton en cada una de las 10 generaciones con alta entropía para las 4 poblaciones evolucionadas, en las 36 condiciones de prueba, los bigotes muestran la desviación estándar.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	NS	
0	***	***	***	NS	NS

Cuadro 4.50: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida 2*, ** $p <= 0.05$, *** $p <= 0.01$

4.6.8. Resultados para las generaciones con baja emisión

En esta condición, medimos nuevamente el rendimiento del 10% de los individuos que mejor se ajustaron a la emisión idealizada según la regla de Hamilton para cada una de las generaciones que mostraban una baja emisión. Se midieron 9 puntos de medición para cada uno de los 4 algoritmos evolutivos.

Resultados estadísticos

Al igual que en las condiciones de alta y baja agrupación, para el análisis estadístico de los puntos de medición de baja emisión se empleó el 10% de los individuos que mejor se ajustaron a la regla de Hamilton en cada grupo a lo largo de las 6 condiciones de parentesco para las generaciones que presentaban una alta entropía. Al igual que en el caso anterior, para dicho análisis se utilizó una prueba ANOVA de medidas repetidas de una vía para cada grupo.

En las pruebas con comida 2.0, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 102$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Al emplear una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 2.0 unidades de comida bajo todas las condiciones de parentesco, se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones (**tabla 4.50**), excepto por las condiciones: 0.6 y 0.4 ($p = 1$), 0.4 y 0.2 ($p = 1$), 0.4 y 0 ($p = 0.1$), y 0.2 y 0 ($p = 1$).

0.6 y 0.4 $p = 1$, 0.4 y 0.2 $p = 1$, 0.4 y 0 $p = 0.1$, 0.2 y 0 $p = 1$.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	NS	NS	
0	***	***	***	NS	NS

Cuadro 4.51: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.8, ** $p \leq 0.05$, *** $p \leq 0.01$

En las pruebas con comida 1.8, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 143$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.8 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones (**tabla 4.51**), excepto por las condiciones 0.6 y 0.4 ($p = 0.09$), 0.6 y 0.2 ($p = 0.14$), 0.4 y 0.2 ($p = 1$), 0.4 y 0 ($p = 1$), y 0.2 y 0 ($p = 1$).

En las pruebas con comida 1.6, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 140$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.6 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones (**tabla 4.52**), excepto por las condiciones 0.6 y 0.4 ($p = 1$), 0.4 y 0.2 ($p = 0.248$) y 0.2 y 0 ($p = 1$).

En las pruebas con comida 1.4, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 122$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba t de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.4 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferen-

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	***	NS	
0	***	***	**	**	NS

Cuadro 4.52: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 1.6 , ** $p \leq 0.05$, *** $p \leq 0.01$

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	NS	NS	
0	***	***	***	***	NS

Cuadro 4.53: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 1.4 , ** $p \leq 0.05$, *** $p \leq 0.01$

cias significativas $p < 0.05$ entre todas las condiciones (**tabla 4.53**), excepto por las condiciones 0.6 y 0.4 ($p = 1$), 0.6 y 0.2 ($p = 1$), 0.4 y 0.2 ($p = 1$), 0.4 y 0 ($p = 0.27$) y 0.2 y 0 ($p = 1$).

En las pruebas con comida 1.2 el ANOVA de medidas repetidas reveló un efecto significativo del Parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 120$, $p < 0.05$.

Además, se ha aplicado una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba *t* de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.2 unidades de comida, bajo todas las condiciones de parentesco, encontramos diferencias significativas $p < 0.05$ entre todas las condiciones (**table 4.54**) excepto por las condiciones; 0.4 y 0.2 $p = 1$, 0.4 y 0 $p = 1$, 0.2 y 0 $p = 1$.

En las pruebas con comida 1.0, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 116$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba *t* de múltiples comparaciones y una vía con correc-

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	***		
0.2	***	***	**	NS	
0	***	***	***	NS	NS

Cuadro 4.54: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.2 , ** $p \leq 0.05$, *** $p \leq 0.01$

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	NS	NS	
0	***	***	NS	NS	NS

Cuadro 4.55: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.0 , ** $p \leq 0.05$, *** $p \leq 0.01$

ción de Bonferroni para comparar el grupo en la condición de 1.0 unidades de comida bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones (**tabla 4.55**), excepto por las condiciones 0.6 y 0.4 ($p = 0.06$), 0.6 y 0.2 ($p = 1$), 0.6 y 0 ($p = 0.7$), 0.4 y 0.2 ($p = 1$), 0.4 y 0 ($p = 1$), y 0.2 y 0 ($p = 0.67$).

Una vez más, podemos observar el mismo fenómeno que se presenta en los puntos de medición previos. En estos casos, los individuos que mejor se ajustan a la emisión idealizada muestran una clara tendencia a aumentar la emisión de luz azul a medida que aumenta el parentesco entre ellos. La precisión de este mecanismo es notable cuando se distingue entre individuos con un parentesco de 1 en comparación con aquellos que tienen un parentesco de 0.8. Sin embargo, como en los dos puntos de medición anteriores, el mecanismo de discriminación por parentesco carece de precisión cuando se trata de comparaciones entre dos condiciones con un bajo nivel de parentesco, donde las diferencias entre ellas dejan de ser significativas.

Estos resultados respaldan la hipótesis de que la conducta de discriminación por parentesco surge temprano en el desarrollo evolutivo y persiste a lo largo de todo el proceso evolutivo, en mayor o menor medida. Hasta el momento, esta conducta se ha encontrado presente en todos nuestros puntos de medición, ya sea en las poblaciones agrupadas, dispersas en el espacio

de solución o en las generaciones más egoístas, sin desaparecer del acervo genético.

Además, se ha observado que incluso en las generaciones en las que la emisión de luz azul es baja, es decir, cuando la mayoría de los individuos muestran poco altruismo, aún existe un subconjunto de ellos que mantiene un comportamiento similar al observado en las generaciones con una alta emisión. Esto indica que la conducta altruista asociada a la discriminación por parentesco persiste en el acervo genético, incluso en las generaciones menos altruistas.

En cuanto a las pruebas con comida, se ha encontrado que el comportamiento de emisión de luz no parece correlacionarse con la cantidad de comida presente en el entorno. Estos hallazgos sugieren que la discriminación por parentesco es un mecanismo independiente de la disponibilidad de recursos y que su presencia en las poblaciones es independiente de la cantidad de comida disponible.

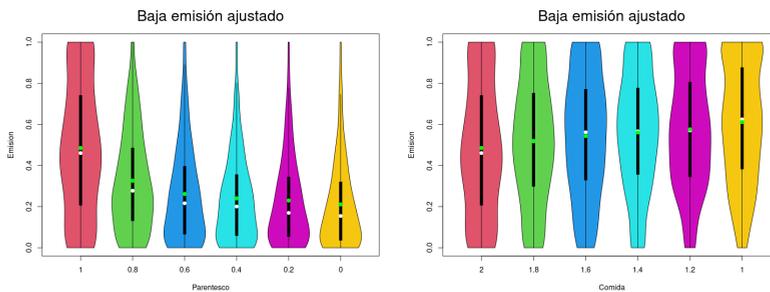


Figura 4.65: Gráfica de violines para el 10% de individuos que mejor se ajustan a la emisión idealizada de las generaciones más emisoras, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana.

Baja emisión experimento 5

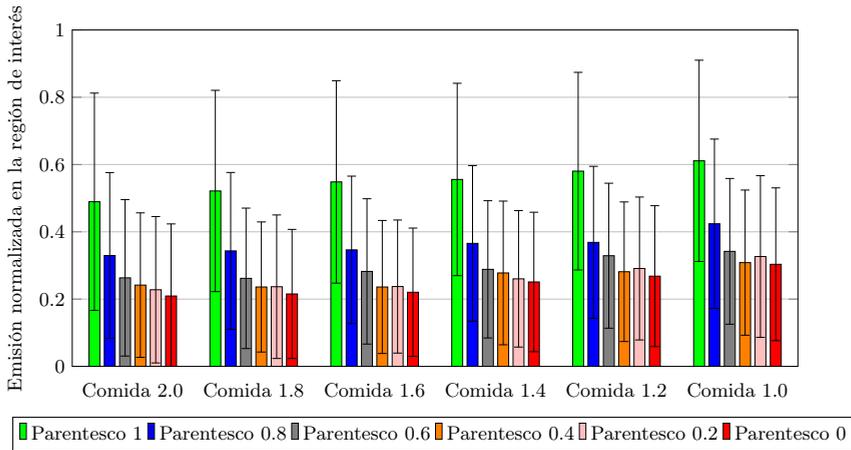


Figura 4.66: Diferencias de emisión de luz según el nivel de parentesco para los 10 individuos con emisión normalizada que más se ajustan a la regla de Hamilton en cada una de las 10 generaciones con alta entropía para las 4 poblaciones evolucionadas, en las 36 condiciones de prueba, los bigotes muestran la desviación estándar.

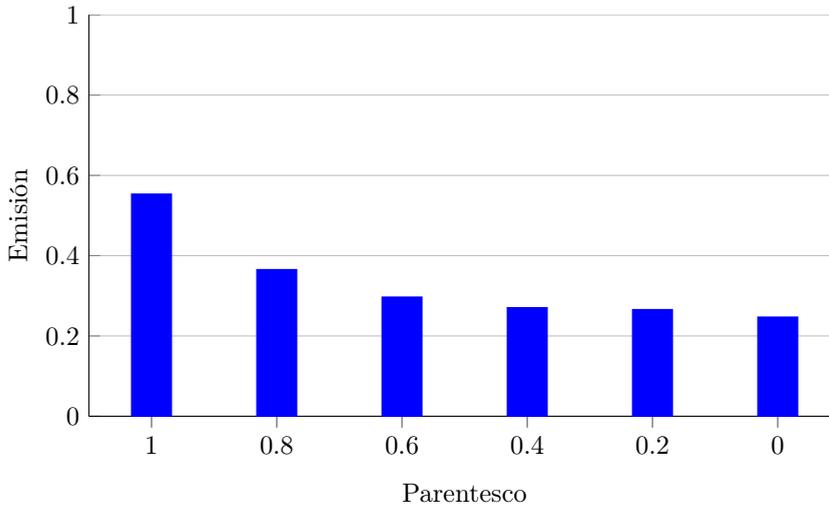


Figura 4.67: Promedio de emisión de los individuos que mejor se ajustan a la emisión idealizada para las 9 generaciones con menos emisión de cada uno de las 4 ejecuciones del algoritmo evolutivo, agrupadas según la cantidad de parentesco presente en cada una de las 36 condiciones de prueba.

4.6.9. Resultados para las generaciones con alta emisión

Finalmente, evaluamos el comportamiento del 10% de individuos que mejor se ajustan a la emisión idealizada de conformidad con la regla de Hamilton de cada una de las generaciones que presentaron una alta emisión (9 puntos de medición para cada uno de los 4 algoritmos evolutivos).

Resultados estadísticos

Para el análisis estadístico de los puntos de medición de alta emisión, solo utilizamos el 10% de individuos que mejor se ajustaron a la regla de Hamilton en cada grupo a lo largo de las 6 condiciones de parentesco para las generaciones que presentaban una alta entropía. Al igual que en los casos anteriores, para dicho análisis utilizamos una prueba ANOVA de medidas repetidas de una vía para cada grupo.

En las pruebas con comida 2.0, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 203$, $p < 0.05$. Además, se aplicó

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	**	NS	
0	***	***	***	**	NS

Cuadro 4.56: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida 2* puntos de medición de alta emisión, ** $p \leq 0.05$, *** $p \leq 0.01$

una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

En las pruebas con comida 1.8, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 214, p < 0.05$.

Se utilizó una prueba *T* de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 2.0 unidades de comida, bajo todas las condiciones de parentesco, encontramos diferencias significativas $p < 0.05$ entre todas las condiciones (**table 4.56**) excepto por las condiciones; 0.6 y 0.4 $p=1$, 0.4 y 0.2 $p= 1$, 0.2 y 0 $p=1$.

En las pruebas con comida 1.8, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 214, p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba *T* de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.8 unidades de comida, bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones, excepto por las condiciones 0.4 y 0.2 ($p=1$), 0.4 y 0 ($p=1$), y 0.2 y 0 ($p=1$). Los resultados se muestran en la **tabla 4.57**.

En las pruebas con comida 1.6, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 227, p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba *T* de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.6 unidades de comida, bajo todas las condiciones de parentesco. Se encontraron dife-

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	***		
0.2	***	***	***	NS	
0	***	***	***	NS	NS

Cuadro 4.57: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.8 puntos de medición de alta emisión, ** $p \leq 0.05$, *** $p \leq 0.01$

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	***		
0.2	***	***	***	NS	
0	***	***	***	NS	NS

Cuadro 4.58: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.6 puntos de medición de alta emisión, ** $p \leq 0.05$, *** $p \leq 0.01$

rencias significativas $p < 0.05$ entre todas las condiciones, excepto por las condiciones 0.4 y 0.2 ($p=1$), 0.4 y 0 ($p=0.5$), y 0.2 y 0 ($p=1$). Los resultados se muestran en la **tabla 4.58**.

En las pruebas con comida 1.4, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5,1800) = 205$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba T de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.4 unidades de comida, bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones, excepto por las condiciones 0.4 y 0.2 ($p = 0.1$) y 0.2 y 0 ($p = 1$). Los resultados se muestran en la **tabla 4.59**.

En las pruebas con comida 1.2, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5,1800) = 185$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	**		
0.2	***	***	***	**	
0	***	***	***	NS	NS

Cuadro 4.59: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.4 puntos de medición de alta emisión, ** $p \leq 0.05$, *** $p \leq 0.01$

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	**		
0.2	***	***	***	**	
0	***	***	***	NS	NS

Cuadro 4.60: Resultados de los valores p para comparaciones múltiples, prueba t de una vía con corrección de Bonferroni, Grupo *comida* 1.2 puntos de medición de alta emisión, ** $p \leq 0.05$, *** $p \leq 0.01$

Se utilizó una prueba T de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 2.0 unidades de comida, bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre todas las condiciones, excepto por las condiciones 0.4 y 0.2 ($p = 0.22$) y 0.2 y 0 ($p = 1$). Los resultados se muestran en la **tabla 4.60**.

En las pruebas con comida 1.0, el ANOVA de medidas repetidas reveló un efecto significativo del parentesco en la emisión de luz azul dentro de la región de interés, con $F(5, 1800) = 135$, $p < 0.05$. Además, se aplicó una corrección de esfericidad (ajuste de Greenhouse-Geisser) debido a las diferencias en la varianza observadas en la prueba de Mauchly.

Se utilizó una prueba T de múltiples comparaciones y una vía con corrección de Bonferroni para comparar el grupo en la condición de 1.0 unidades de comida, bajo todas las condiciones de parentesco. Se encontraron diferencias significativas $p < 0.05$ entre la mayoría de las condiciones, como se muestra en la **tabla 4.61**, excepto por las siguientes condiciones: 0.6 y 0.4 ($p = 1$), 0.6 y 0.2 ($p = 0.94$), 0.6 y 0 ($p = 0.6$), 0.4 y 0.2 ($p = 1$), 0.2 y 0 ($p = 1$).

Al igual que en los puntos de medición anteriores, cuando medimos el

Parentesco	1	0.8	0.6	0.4	0.2
0.8	***				
0.6	***	***			
0.4	***	***	NS		
0.2	***	***	NS	NS	
0	***	***	NS	NS	NS

Cuadro 4.61: Resultados de los valores p para comparaciones múltiples, prueba *t* de una vía con corrección de Bonferroni, Grupo *comida* 1.0 puntos de medición de alta emisión, ** $p \leq 0.05$, *** $p \leq 0.01$

comportamiento del 10% superior de los individuos que mejor se ajustan a la emisión idealizada según la regla de Hamilton para cada generación con alta emisión, los individuos que mejor se ajustan a la emisión idealizada también mostraron una clara preferencia por emitir más luz azul a medida que aumenta el parentesco entre ellos, tanto en cada una de las 36 condiciones como cuando agrupamos a los individuos sólo por parentesco. Sin embargo, al igual que en los casos anteriores, el comportamiento de emisión de luz no parece correlacionarse con la cantidad de alimento presente en el entorno.

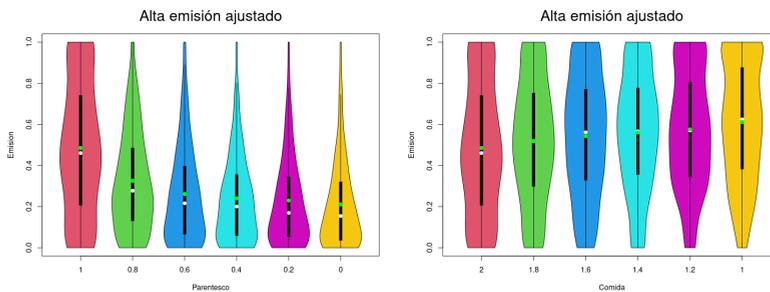


Figura 4.68: Gráfica de violines para el 20% de individuos más emisor de las generaciones más emisoras, tanto cuando las agrupamos por nivel de parentesco como por nivel de comida presente durante las pruebas de altruismo, el punto blanco representa el promedio de emisión y el verde la mediana.

Alta emisión experimento 5

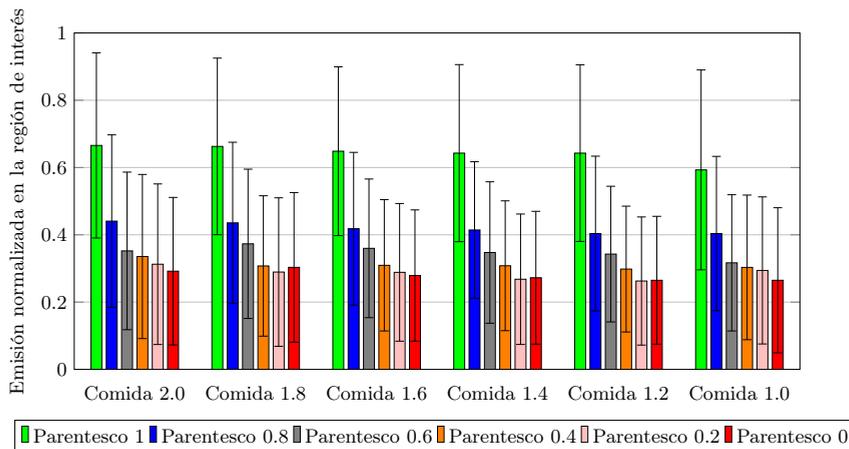


Figura 4.69: Diferencias de emisión de luz según el nivel de parentesco para los 10 individuos con emisión normalizada que más se ajustan a la regla de Hamilton en cada una de las 10 generaciones con alta entropía para las 4 poblaciones evolucionadas, en las 36 condiciones de prueba, los bigotes muestran la desviación estándar.

Como se puede apreciar en los gráficos presentados en la Figura 4.69 y la Figura 4.70, en las cuatro ejecuciones del algoritmo evolutivo, una fracción de la población exhibe consistentemente a lo largo de todas las generaciones evaluadas la conducta de aumentar la emisión de luz en la región de interés en relación con la percepción de parentesco. Es importante destacar que es prácticamente improbable que el incremento en la emisión de luz relacionado con el parentesco sea el resultado de un artefacto de la red neuronal. Esto se debe a dos razones fundamentales:

En primer lugar, esta conducta persiste en individuos con diversos fenotipos, lo que sugiere que no se trata de una característica accidental de la arquitectura neuronal.

En segundo lugar, el hecho de que los valores RGB del color del otro individuo sean los que permiten a los robots inferir su grado de parentesco asegura que la intensidad de las entradas de la red neuronal no tenga ninguna relación con el nivel de parentesco que comparten dos robots entre sí.

En contraste, en ninguno de los cuatro experimentos del algoritmo evolutivo se observa la conducta de aumentar la emisión de luz en presencia de mayor cantidad de comida, a pesar de que en teoría esta conducta podría

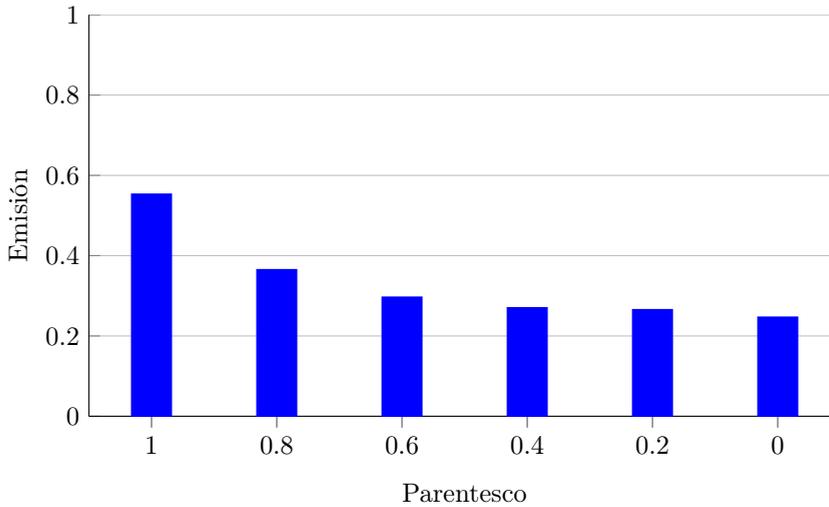


Figura 4.70: Promedio de emisión de los individuos que mejor se ajustan a la emisión idealizada para las 9 generaciones con mayor emisión de cada una de las 4 ejecuciones del algoritmo evolutivo, agrupadas según la cantidad de parentesco presente en cada una de las 36 condiciones de prueba.

considerarse más fácil de aprender para una red neuronal debido a la forma en que dicho valor está codificado en sus entradas. Esto revela que, al menos bajo estas condiciones de evolución, donde la cantidad de comida en el entorno varía constantemente, discriminar en función del parentesco resulta ser una conducta evolutivamente más sencilla de alcanzar y mantener en el acervo genético de nuestras poblaciones que discriminar en función de la cantidad de comida.

Esto revela que, al menos bajo estas condiciones de evolución, donde la cantidad de comida en el entorno varía constantemente, discriminar en función del parentesco resulta ser una conducta evolutivamente más sencilla de alcanzar y mantener en el acervo genético de nuestras poblaciones que discriminar en función de la cantidad de comida.

Experimento	Resultados del experimento				Conducta evolucionada
	Condicio- nes	Comida	Parentesco	¿Es la señal confiable?	
1	6	1, 1.2, 1.4, 1.6, 1.8, 2	normalizado	Sí	Altruismo selectivo
1.1	1	2	Normalizado invertido	Sí	Altruismo selectivo
2.1	1	2	RGB	Sí	Altruismo selectivo
2.2	1	1 a 2	RGB	Sí	Altruismo selectivo ***
3.1	1	2	RGB	Sí	Altruismo ingenuo
3.2	1	1 a 2	RGB	No	No evoluciona una conducta medible
4	1	1 a 2	RGB	No	Navegación a ciegas
5	1	1 a 2	RGB	Sí	Altruismo selectivo ***

Cuadro 4.62: Condiciones y resultados de los experimentos realizados en esta tesis (*** solo en una parte de la población) .

CAPÍTULO 5

Conclusiones

Uno de los objetivos principales de esta tesis fue demostrar si era posible evolucionar comportamientos altruistas utilizando los principios de la evolución biológica, sin manipular el parentesco de los individuos durante el proceso evolutivo y utilizando poblaciones heterogéneas de robots. Los resultados del Experimento 1 (véase la sección 4.1) demostraron que esto es posible.

En este experimento, pudimos hacer evolucionar comportamientos altruistas en poblaciones heterogéneas inicializadas aleatoriamente. No necesitamos manipular el parentesco entre individuos durante el proceso evolutivo, y cualquier grado de parentesco exhibido por dos robots en la misma generación era el resultado de procesos de evolución biológica como la selección, la mutación y la deriva genética en nuestros algoritmos evolutivos.

Es importante destacar que la aparición del comportamiento altruista utilizando selección individual y poblaciones heterogéneas es algo que no se había informado en la literatura hasta ahora, como señalamos en la sección sobre el estado de arte (véase la sección 2.5). A pesar de los numerosos artículos que abordan esta cuestión, este comportamiento sólo evolucionaba cuando se utilizaban poblaciones homogéneas o selección de grupo, o cuando se manipulaba el número de clones presentes en una población de un algoritmo evolutivo. Dadas las condiciones de evolución del experimento uno, pudimos atribuir estos resultados a dos factores principales:

- La aparición de comportamientos altruistas en este tipo de tareas requiere la existencia de un mecanismo de discriminación del parentesco. En nuestros resultados, los robots reciben como entrada el valor numérico del parentesco con el otro robot presente en la arena, lo que les permite evolucionar un comportamiento de altruismo selectivo. Prefieren señalar la presencia de comida a los individuos muy emparentados y tienden a no señalar a los menos emparentados. Este mecanismo permite que los comportamientos altruistas, incluso los ingenuos, prosperen a pesar de la existencia de individuos egoístas en la población.

- La cantidad de comida presente en la zona de interés también es fundamental para la aparición y frecuencia de conductas altruistas, siempre y cuando se mantenga constante durante la evolución de las poblaciones. Dichas conductas solo surgen en condiciones con una cantidad de comida superior a 1.4, y aumentan a medida que aumenta la cantidad de comida.

Dado que llevamos a cabo cuatro ejecuciones independientes en cada una de las condiciones de evolución del experimento 1, y en todas ellas se converge en una solución del mismo tipo, es factible afirmar lo siguiente:

- Cuando existe un mecanismo de discriminación por parentesco, la regla de Hamilton tiene un valor predictivo siempre que la cantidad de alimento presente en el entorno permanezca estable a lo largo del proceso evolutivo.
- Como predice la regla de Hamilton, la emisión de luz azul dentro de la región de interés aumentó en condiciones de mayor abundancia de alimento y mayor parentesco, en comparación con las condiciones en las que la cantidad de alimento y el parentesco disminuyeron. Esto hizo que la aplicación de la regla de Hamilton arrojara valores próximos a cero, y en estas condiciones de prueba, el comportamiento de emisión de luz azul dentro de la región de interés se extinguió en nuestras poblaciones.
- Aunque se observó un incremento no significativo de la emisión de luz en la condición de comida 1.2 y parentesco cero, este fenómeno se puede explicar como consecuencia de que durante la evolución de nuestras poblaciones el parentesco entre los robots nunca se acerca a cero. Además, en estas condiciones de escasez de comida, la conducta de no emitir luz azul en la región de interés es evolutivamente ventajosa, lo que provoca que dicha señal de entrada sea usada para incrementar la supresión de la conducta de emitir luz azul. Al desaparecer esta supresión, la emisión de luz azul se incrementa, aunque sea de forma marginal. Por lo tanto, este aparente incremento es solo un artefacto provocado por la estructura de nuestra red neuronal.

Como se muestra en el experimento 1.1, el comportamiento de emitir luz azul en relación con el parentesco no es producto de un artefacto de nuestra red neuronal o de cómo pre procesamos las entradas. Esto confirma aún más nuestra hipótesis de que, una vez que existe un mecanismo capaz

de discriminar el parentesco, la evolución de los comportamientos altruistas se producirá sistemáticamente si la cantidad de recursos del entorno la convierten en una estrategia evolutivamente estable.

En general, los resultados del experimento 1 nos muestran que aunque la regla de Hamilton no establece explícitamente como requisito para la emergencia de conductas altruistas la existencia de un mecanismo de reconocimiento y discriminación por parentesco, esta parece ser una condición necesaria para el surgimiento de conductas altruistas en agentes artificiales en tareas que involucran forrajeo, cuando se utilizan poblaciones heterogéneas y selección individual.

Por lo tanto, era necesario responder si este mecanismo de discriminación por parentesco podía evolucionar por sí mismo siguiendo los mismos principios y usando la misma tarea. Los experimentos 2.1 y 3.1 ayudaron a responder esta pregunta:

- Ambos experimentos confirman que es posible evolucionar la conducta altruista en poblaciones de agentes artificiales heterogéneas y con selección individual.
- Además, demuestran que la existencia de una expresión fenotípica del genotipo del robot (en nuestro caso, asignando un color a cada robot en función de los valores de su red neuronal) y permitiendo que el otro robot perciba este color es suficiente para que evolucione un mecanismo de discriminación por parentesco similar al propuesto por Richard Dawkins, conocido como "la barba verde". Aunque en el Experimento 3.1, las poblaciones evolucionadas desarrollan conductas de altruismo ingenuo, al menos en el 20% más altruista de la población.
- Estos experimentos demuestran que incluso redes neuronales relativamente simples pueden evolucionar no solo conductas altruistas basadas en la discriminación por parentesco, sino también desarrollar el propio mecanismo que permite esta discriminación. Esto ocurre cuando existe una representación fenotípica del genotipo del robot que es percibida por el otro robot. Además, es notable que este fenómeno se produce con facilidad en condiciones de abundancia de comida en el entorno, especialmente si esta comida se mantiene constante a lo largo del proceso evolutivo.

Es notable que, a pesar de que las redes neuronales utilizadas en los experimentos 2.1 y 3.1 no son particularmente complejas, lograron evolucionar tres comportamientos o mecanismos distintos. En primer lugar, desarrollaron la capacidad de encontrar la región de interés utilizando la emisión de

luz azul de los otros robots. En segundo lugar, crearon un mecanismo para detectar el parentesco que el otro robot tenía con el robot que realizaba la prueba, basándose únicamente en el color del otro robot. Por último, desarrollaron un mecanismo para modular la conducta altruista basándose en esta discriminación por parentesco. Todo esto se logró sin que la evolución del mecanismo de reconocimiento y discriminación por parentesco fuera premiada de manera explícita en nuestra función de aptitud.

Si bien el altruismo no evolucionó tan fácilmente ni con tanta intensidad en las poblaciones evolucionadas en condiciones de comida variable:

En el experimento 2.2, donde solo un subconjunto de la población desarrolla un mecanismo de discriminación por parentesco, el cual solo discrimina entre individuos del mismo color (parentesco 1) y el resto de la población. Sin embargo, el nivel de altruismo selectivo presente es suficiente para evitar que la conducta de emitir luz azul se extinga del acervo genético, mostrando que es posible aún en condiciones no ideales que las mismas tres conductas que en la condición de abundancia: encontrar la región de interés utilizando la luz azul, un mecanismo capaz de detectar el nivel de parentesco con otro robot solo utilizando una expresión fenotípica del mismo (su color) y, por último, un mecanismo capaz de modular la conducta del robot basado en la discriminación por parentesco. En el experimento 3.2, no evoluciona la conducta de encontrar la región de interés utilizando la luz azul, lo cual podría deberse a la simplicidad de la red neuronal utilizada. Muy probablemente, una red con solo una capa oculta no es capaz de generalizar una solución para todos los inputs presentados a la red.

Sin embargo, aumentar la complejidad de la red neuronal no garantiza la evolución de conductas altruistas, incluso en situaciones en las que ya se habían encontrado de manera limitada. Un ejemplo de esto es el experimento 4, en el que se agregó una capa oculta a la red neuronal en comparación con el experimento 2.2.

En este experimento, los robots aprenden a navegar a ciegas para encontrar la región de interés, lo que hace que la luz azul carezca de significado para ellos. Debido a la función de aptitud utilizada, esta es otra solución posible al problema planteado y una en la que se estancaron las cuatro ejecuciones evolutivas durante este experimento.

Es importante destacar que esta afirmación no refuta las conclusiones que se pueden extraer del resto de los experimentos. Por el contrario, ilustra la gran habilidad que los algoritmos evolutivos poseen para encontrar soluciones inesperadas a los problemas que deben resolver.

En el Experimento 5, se evolucionan nuevamente los tres mecanismos encontrados en experimentos anteriores: la capacidad de utilizar la luz azul

para navegar hacia la comida, un mecanismo capaz de determinar el parentesco con otro robot utilizando su color, y un mecanismo de discriminación del parentesco más refinado que en los experimentos previos, presente en un subconjunto de la población.

Este mecanismo es capaz de mostrar un comportamiento diferenciado en función del grado de parentesco con el otro individuo presente en la arena. El hecho de que sea más sofisticado que el presente en los Experimentos 2 y 3 puede deberse al aumento de la complejidad de la red y al hecho de que el robot conocía tanto el color del otro individuo como el suyo propio. La capacidad de un mismo robot para mostrar comportamientos significativamente diferentes en función de las condiciones ambientales, en este caso, la cantidad de parentesco presente en otro robot, habla de la flexibilidad conductual que puede conseguirse con los algoritmos evolutivos, aunque esto no se vea recompensado directamente en la función de aptitud.

Aunque ninguna de nuestras poblaciones se ajusta totalmente a los valores esperados dados por el ajuste ideal a la regla de Hamilton, sabemos por la literatura que, aunque los algoritmos evolutivos son eficaces para encontrar buenas soluciones a problemas de alta dimensión, es casi seguro que no encontrarán la solución óptima.

En esta tesis, se ha explorado cómo replicar fenómenos presentes en la evolución biológica, como la selección y discriminación por parentesco, en agentes artificiales simulados. Se han identificado las condiciones esenciales para generar comportamientos de comunicación y altruismo en estos agentes siguiendo los principios de la teoría evolutiva. Además, se ha demostrado que este enfoque de modelado puede dar como resultado agentes menos reactivos y más flexibles.

En resumen, se han respondido las siguientes preguntas de investigación:

- ¿Es posible lograr el surgimiento de comunicación y altruismo en agentes artificiales usando los principios de la teoría de la evolución biológica?
- ¿Cuáles son las condiciones mínimas necesarias que deben ser modeladas para este propósito?
- ¿Podemos estudiar procesos cognitivos usando este tipo de modelado?
- ¿Este tipo de modelado puede ayudar a generar conductas más flexibles en agentes artificiales?

Hemos logrado el surgimiento de comunicación y conductas altruistas siguiendo los principios de la teoría de la evolución, sabemos que las condiciones mínimas son la existencia de un mecanismo de discriminación por

parentesco o la posibilidad de su evolución, así como cierto nivel mínimo de presencia de comida. Hemos entendido que es lo que propicia el surgimiento de estos procesos cognitivos desde el punto de vista evolutivo y mostrado cómo este tipo de modelado genera conductas más flexibles en estos agentes artificiales.

Referencias

- Auerbach, J. E., y Bongard, J. C. (2012). On the relationship between environmental and morphological complexity in evolved robots. En *Proceedings of the fourteenth international conference on genetic and evolutionary computation conference - gecco '12* (p. 521). New York, New York, USA: ACM Press. Descargado de <http://dl.acm.org/citation.cfm?doid=2330163.2330238> doi: 10.1145/2330163.2330238
- Axelrod, R., y Hamilton, W. (1981, mar). The evolution of cooperation. *Science*, 211(4489), 1390–1396. Descargado de <http://www.ncbi.nlm.nih.gov/pubmed/16938860><http://www.sciencemag.org/cgi/doi/10.1126/science.7466396> doi: 10.1126/science.7466396
- Banzhaf, W., Beslon, G., Christensen, S., Foster, J. a., Képès, F., Lefort, V., ... Ramsden, J. J. (2006). Guidelines: From artificial evolution to computational evolution: a research agenda. *Nature reviews. Genetics*, 7(9), 729–735. doi: 10.1038/nrg1921
- Bernatskiy, A., y Bongard, J. (2018). Evolving morphology automatically reformulates the problem of designing modular control. *Adaptive Behavior*, 26(2), 47–64. Descargado de <http://journals.sagepub.com/doi/10.1177/1059712318762807> doi: 10.1177/1059712318762807
- Bongard, J. C. (2013). Evolutionary Robotics. *Communications ACM*, 56(08), 74–83. doi: 10.1145/2493883
- Bourke, A. F. G. (2021, feb). The role and rule of relatedness in altruism. *Nature, Evolution*, 1–2. Descargado de <http://www.nature.com/articles/d41586-021-00210-z> doi: 10.1038/d41586-021-00210-z
- Braitenberg, V. (1986). *Vehicles: Experiments in synthetic psychology*. MIT press.
- Brawer, J., Hill, A., Livingston, K., Aaron, E., Bongard, J., y Long, J. H. (2017, jan). Epigenetic Operators and the Evolution of Physically Embodied Robots. *Frontiers in Robotics and AI*, 4(January). Descargado de <http://journal.frontiersin.org/article/10.3389/frobt.2017.00001/full> doi: 10.3389/frobt.2017.00001
- Brooks, R. a. (1991). How to Build Complete Creatures Rather than Isolated Cognitive Simulators. En K. VanLehn (Ed.), *Architectures for intelligence* (pp. 225–239). Hillsdale, NJ: Erlbaum.

- Cheney, N., Bongard, J., Sunspiral, V., y Lipson, H. (2016). On the Difficulty of Co-Optimizing Morphology and Control in Evolved Virtual Creatures. *Proceedings of the Artificial Life Conference 2016 (ALIFE XV)*, 226—234.
- Cliff, D., Husbands, P., y Harvey, I. (1993). Explorations in Evolutionary Robotics. *Adaptive Behavior*, 2(1), 73–110. doi: 10.1177/105971239300200104
- Cocroft, R. B., y Rodríguez, R. L. (2005). The behavioral ecology of insect vibrational communication. *BioScience*, 55(4), 323–334. doi: 10.1641/0006-3568(2005)055[0323:TBEQIV]2.0.CO;2
- Coello, C. A. C. (2004). *Introducción a la Computación Evolutiva (Notas de Curso)* (n.º 2508).
- Dawkins, R. (1976). *The selfish gene: with a new introduction by the author.* UK: Oxford University Press. (Originally published in 1976).
- De Jong, K. A. (1975). *Analysis of the Behavior of a Class of Genetic Adaptive Systems* (Tesis Doctoral no publicada). University of Michigan.
- Dennett, D. C. (2002). The new replicators. *The encyclopedia of evolution*, 1, E83–E92.
- Doncieux, S., Bredeche, N., Mouret, J.-B., y Eiben, A. E. G. (2015, mar). Evolutionary Robotics: What, Why, and Where to. *Frontiers in Robotics and AI*, 2(March), 1–18. Descargado de <http://www.frontiersin.org/Evolutionary{ }Robotics/10.3389/frobt.2015.00004/abstract> doi: 10.3389/frobt.2015.00004
- Endler, J. A. (1993, may). Some General Comments on the Evolution and Design of Animal Communication Systems. *Philosophical Transactions of the Royal Society B: Biological Sciences*, 340(1292), 215–225. Descargado de <http://rstb.royalsocietypublishing.org/cgi/doi/10.1098/rstb.1993.0060> doi: 10.1098/rstb.1993.0060
- Floreano, D., y Keller, L. (2010, jan). Evolution of Adaptive Behaviour in Robots by Means of Darwinian Selection. *PLoS Biology*, 8(1), e1000292. Descargado de <http://dx.plos.org/10.1371/journal.pbio.1000292> doi: 10.1371/journal.pbio.1000292
- Floreano, D., Mitri, S., Magnenat, S., y Keller, L. (2007, mar). Evolutionary conditions for the emergence of communication in robots. *Current biology : CB*, 17(6), 514–9. Descargado de <http://linkinghub.elsevier.com/retrieve/pii/S0960982207009281><http://www.ncbi.nlm.nih.gov/pubmed/17320390> doi: 10.1016/j.cub.2007.01.058

- Floreano, D., Mitri, S., Perez-Uribe, A., y Keller, L. (2008). Evolution of altruistic robots. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 5050 LNCS, 232–248. doi: 10.1007/978-3-540-68860-0_11
- Gonzalez-Grandón, X., y Froese, T. (2018, oct). Grounding 4E Cognition in Mexico: introduction to special issue on spotlight on 4E Cognition research in Mexico. *Adaptive Behavior*, 26(5), 189–198. Descargado de <http://journals.sagepub.com/doi/10.1177/1059712318791633> doi: 10.1177/1059712318791633
- Hamilton, W. D. (1963, sep). The Evolution of Altruistic Behavior. *The American Naturalist*, 97(896), 354–356. Descargado de <https://www.journals.uchicago.edu/doi/10.1086/497114> doi: 10.1086/497114
- Harnad, S. (1990). The Symbol Grounding Problem. *Physica D: Nonlinear Phenomena*(1990), 335–346. Descargado de <http://eprints.soton.ac.uk/258175/1/sgproblem1.html> doi: 10.1016/0167-2789(90)90087-6
- Harvey, I., Husbands, P., Cliff, D., Thompson, a., y Jakobi, N. (1997). Evolutionary robotics: the sussex approach. *Robotics and autonomous systems*(May 1996), 1–32. Descargado de [http://dx.doi.org/10.1016/S0921-8890\(96\)00067-X](http://dx.doi.org/10.1016/S0921-8890(96)00067-X) doi: 10.1016/S0921-8890(96)00067-X
- Harvey, I., Paolo, E. D., Wood, R., Quinn, M., y Tuci, E. (2005). Evolutionary Robotics: A New Scientific Tool for Studying Cognition. *Artificial Life*, 11(1-2), 79–98. doi: 10.1162/1064546053278991
- Holland, J. H. (1975). Adaptation in Natural and Artificial Systems: An introductory Analysis with Applications to Biology, Control and Artificial Intelligence. *MIT Press*, 183. Descargado de <http://www.citeulike.org/group/664/article/400721> doi: 10.1137/1018105
- Holland, J. H. (1992). Genetic algorithms. *Scientific american*, 267(1), 66–73.
- Jain, A. K., Mao, J., y Mohiuddin, K. M. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31–44.
- Jost, L. (2006, may). Entropy and diversity. *Oikos*, 113(2), 363–375. Descargado de <https://onlinelibrary.wiley.com/doi/10.1111/j.2006.0030-1299.14714.x> doi: 10.1111/j.2006.0030-1299.14714.x
- Kawecki, T. J., Lenski, R. E., Ebert, D., Hollis, B., Olivieri, I., y Whitlock, M. C. (2012, oct). Experimental evolution. *Trends in ecology & evolution*, 27(10), 547–60. Descargado de <http://dx.doi.org/10.1016/j>

- .tree.2012.06.001<http://linkinghub.elsevier.com/retrieve/pii/S0169534712001425><http://www.ncbi.nlm.nih.gov/pubmed/22819306> doi: 10.1016/j.tree.2012.06.001
- Kay, T., Keller, L., y Lehmann, L. (2020, nov). The evolution of altruism and the serial rediscovery of the role of relatedness. *Proceedings of the National Academy of Sciences*, 117(46), 28894–28898. Descargado de <http://www.pnas.org/lookup/doi/10.1073/pnas.2013596117> doi: 10.1073/pnas.2013596117
- Keller, L., y Ross, K. G. (1998). Selfish genes: A green beard in the red fire ant. *Nature*, 394(6693), 573–575. doi: 10.1038/29064
- Kiverstein, J., y Clark, A. (2009, mar). Introduction: Mind Embodied, Embedded, Enacted: One Church or Many? *Topoi*, 28(1), 1–7. Descargado de <http://link.springer.com/10.1007/s11245-008-9041-4> doi: 10.1007/s11245-008-9041-4
- Kohonen, T. (1997). *Self-organizing maps* (3rd ed ed.). Springer Berlin Heidelberg. Descargado de <http://gen.lib.rus.ec/book/index.php?md5=3D5908DFE8DEA923886598A0983BB384>
- Kohonen, T. (2001). *Self-organizing maps. new york: Springer series in information sciences*. Springer.
- Lara, B., Astorga, D., Mendoza-Bock, E., Pardo, M., Escobar, E., y Ciriya, A. (2018). Embodied Cognitive Robotics and the learning of sensorimotor schemes. *Adaptive Behavior*, 26(5), 225–238. doi: 10.1177/1059712318780679
- Lara, B., Gaona, W., Escobar, E., Pardo, J. M., y Hermosillo-Valadez, J. (2020). Development of body-based spatial knowledge through mental imagery in an artificial agent. *Adaptive Behavior*. doi: 10.1177/1059712319895604
- Lehman, J., y Miikkulainen, R. (2014). Overcoming Deception in Evolution of Cognitive Behaviors. *Genetic and Evolutionary Computation Conference*(July), <http://dx.doi.org/10.1145/2576768.2598300>. doi: 10.1145/2576768.2598300
- Lehman, J., y Stanley, K. O. (2008). Exploiting open-endedness to solve problems through the search for novelty. *Artificial Life XI*(Alife Xi), 329–336. doi: 10.1.1.365.3998
- Lehman, J., Wilder, B., y Stanley, K. O. (2016). On the Critical Role of Divergent Selection in Evolvability. *Frontiers in Robotics and AI*, 3(August), 1–7. Descargado de <http://journal.frontiersin.org/Article/10.3389/frobt.2016.00045/abstract> doi: 10.3389/frobt.2016.00045
- Lenski, R. E., Rose, M. R., Simpson, S. C., y Tadler, S. C. (1991, dec).

- Long-Term Experimental Evolution in *Escherichia coli*. I. Adaptation and Divergence During 2,000 Generations. *The American Naturalist*, 138(6), 1315–1341. Descargado de <http://www.journals.uchicago.edu/doi/10.1086/285289> doi: 10.1086/285289
- Magenat, S., Waibel, M., y Beyeler, A. (2009). Enki: The fast 2d robot simulator (2009). URL <http://lis.epfl.ch/resources/enki>.
- McCulloch, W. S., y Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115–133.
- Mehrotra, K., Mohan, C. K., y Ranka, S. (1997). *Elements of artificial neural networks*. MIT press.
- Menary, R. (2010). Introduction to the special issue on 4E cognition. *Phenomenology and the Cognitive Sciences*, 9(November), 459–463. doi: 10.1007/s11097-010-9187-6
- Miller, B. L., y Goldberg, D. E. (1996). Genetic algorithms, selection schemes, and the varying effects of noise. *Evolutionary computation*, 4(2), 113–131.
- Mitri, S., Floreano, D., y Keller, L. (2009). The evolution of information suppression in communicating robots with conflicting interests. *Proceedings of the National Academy of Sciences*, 106(37), 15786–15790.
- Møller, A. P. (2010, apr). False Alarm Calls as a Means of Resource Usurpation in the Great Tit *Parus major*. *Ethology*, 79(1), 25–30. Descargado de <http://doi.wiley.com/10.1111/j.1439-0310.1988.tb00697.x> doi: 10.1111/j.1439-0310.1988.tb00697.x
- Mondada, F., Bonani, M., Raemy, X., Pugh, J., Cianci, C., Klapotcz, A., ... Martinoli, A. (2009). The e-puck, a robot designed for education in engineering. En *Proceedings of the 9th conference on autonomous robot systems and competitions* (Vol. 1, pp. 59–65).
- Newell, A., y Simon, H. A. (1976, mar). Computer science as empirical inquiry. *Communications of the ACM*, 19(3), 113–126. Descargado de <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.136.9841&rep=rep1&type=pdf><http://portal.acm.org/citation.cfm?doid=360018.360022><https://dl.acm.org/doi/10.1145/360018.360022> doi: 10.1145/360018.360022
- Nolfi, S. (2012). Co-evolving predator and prey robots. *Adaptive Behavior*, 20(1), 10–15. doi: 10.1177/1059712311426912
- Nolfi, S., y Floreano, D. (1998). Coevolving predator and prey robots: Do arms races arise in artificial evolution? *Artificial Life*, 4(4), 311–335. doi: 10.1162/106454698568620
- Nolfi, S., y Floreano, D. (2000). *Evolutionary Robotics: The Biology, In-*

- telligence, and Technology of Self-Organizing Machines*. MIT press.
Descargado de <http://gral.istc.cnr.it/nolfi/er-book.html>
- Nowak, M. A. (2006). Five Rules for the Evolution of Cooperation. *science*, 314(5805), 1560–1563.
- Otte, D. (1974, nov). Effects and Functions in the Evolution of Signaling Systems. *Annual Review of Ecology and Systematics*, 5(1), 385–417. Descargado de <http://www.annualreviews.org/doi/10.1146/annurev.es.05.110174.002125> doi: 10.1146/annurev.es.05.110174.002125
- Padje, A. V., Whiteside, M. D., y Kiers, E. T. (2016). ScienceDirect Signals and cues in the evolution of plant – microbe communication. *Current Opinion in Plant Biology*, 32(Figure 1), 47–52. Descargado de <http://dx.doi.org/10.1016/j.pbi.2016.06.006> doi: 10.1016/j.pbi.2016.06.006
- Palacios-leyva, R., Aldana-franco, F., Lara-guzmán, B., y Montes, F. (2017). The impact of population composition for cooperation emergence in evolutionary robotics. *International Journal of Combinatorial Optimization Problems and Informatics*, 8(3), 20–32.
- Pfennig, D. W., Harcombe, W. R., y Pfennig, K. S. (2001). Frequency-dependent Batesian mimicry. *Nature*, 410(6826), 323. doi: 10.1038/35066628
- Pigliucci, M. (2008). Is evolvability evolvable? *Nature Reviews Genetics*, 9(1), 75–82. doi: 10.1038/nrg2278
- Queller, D. C. (2003, jan). Single-Gene Greenbeard Effects in the Social Amoeba *Dictyostelium discoideum*. *Science*, 299(5603), 105–106. Descargado de <https://www.jstor.org/stable/3833236><http://www.sciencemag.org/cgi/doi/10.1126/science.1077742> doi: 10.1126/science.1077742
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Saraswati, A., Hagenbuchner, M., Tsoi, A. C., y cols. (2018). High-resolution self-organizing maps for advanced visualization and dimension reduction. *Neural Networks*, 105, 166–184.
- Schiestl, F. P. (2005). On the success of a swindle: pollination by deception in orchids. *Naturwissenschaften*, 92(6), 255–264.
- Scott-Phillips, T. C., Blythe, R. A., Gardner, A., y West, S. A. (2012, may). How do communication systems emerge? *Proceedings. Biological sciences*, 279(1735), 1943–9. Descargado de <http://www.ncbi.nlm.nih.gov/pubmed/22217724><http://>

- www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC3311886 doi: 10.1098/rspb.2011.2181
- Searcy, W. A., y Nowicki, S. (2005). *The Evolution Of Animal Communication: Reliability And Deception In Signaling Systems* (Vol. 39). Princeton Univ Pr.
- Sims, K. (1994). Evolving 3D Morphology and Behavior by Competition. *Artificial Life*, 1(4), 353–372. Descargado de <http://dx.doi.org/10.1162/artl.1994.1.4.353><http://www.mitpressjournals.org/doi/pdf/10.1162/artl.1994.1.4.353><http://www.mitpressjournals.org/toc/artl/1/4> doi: 10.1162/artl.1994.1.4.353
- Sinervo, B., Chaine, A., Clobert, J., Calsbeek, R., Hazard, L., Lancaster, L., ... Hochberg, M. E. (2006). Self-recognition, color signals, and cycles of greenbeard mutualism and altruism. *Proceedings of the National Academy of Sciences of the United States of America*, 103(19), 7372–7377. doi: 10.1073/pnas.0510260103
- Stanley, K. O., y Miikkulainen, R. (2004). Competitive coevolution through evolutionary complexification. *Journal of Artificial Intelligence Research*, 21, 63–100. doi: 10.1613/jair.1338
- Stanley, K. O., Stanley, K. O., Miikkulainen, R., y Miikkulainen, R. (2002). Efficient Reinforcement Learning Through Evolving Neural Network Topologies. In *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO 2002)*, 10(4), 569–577. Descargado de <http://portal.acm.org/citation.cfm?id=646205.758739>
- Steels, L. (2003). The Evolution of Communication Systems by Adaptive Agents. En *Adaptive agents and multi-agent systems* (pp. 125–140). Descargado de http://link.springer.com/chapter/10.1007/3-540-44826-8_8http://link.springer.com/10.1007/3-540-44826-8_8 doi: 10.1007/3-540-44826-8_8
- Summers, K., y Crespi, B. (2005). Cadherins in maternal-foetal interactions: Red queen with a green beard? *Proceedings of the Royal Society B: Biological Sciences*, 272(1563), 643–649. doi: 10.1098/rspb.2004.2890
- Svozil, D., Kvasnicka, V., y Pospichal, J. (1997). Introduction to multi-layer feed-forward neural networks. *Chemometrics and intelligent laboratory systems*, 39(1), 43–62.
- Valenzo, D., Círia, A., Schillaci, G., y Lara, B. (2022). Grounding context in embodied cognitive robotics. *Frontiers in Neurorobotics*, 16.
- Vonk, J., y Aradhye, C. (2015). Evolution of Cognition. *Basics in Human Evolution*, 479–491. doi: 10.1016/B978-0-12-802652-6.00035-9
- Waibel, M., Floreano, D., y Keller, L. (2011). A quantitative test of Ha-

- milton's rule for the evolution of altruism. *PLoS Biology*, 9(5). doi: 10.1371/journal.pbio.1000615
- Wauters, A. M., Richard-Yris, M. A., Pierre, J. S., Lunel, C., y Richard, J. P. (1999). Influence of chicks and food quality on food calling in broody domestic hens. *Behaviour*, 136(7), 919–933. doi: 10.1163/156853999501649
- Werbos, P. (1974). Beyond regression: New tools for prediction and analysis in the behavior science. *Unpublished Doctoral Dissertation, Harvard University*.
- Wilder, B., y Stanley, K. (2015). Reconciling explanations for the evolution of evolvability. *Adaptive Behavior*, 23(3), 171–179. doi: 10.1177/1059712315584166
- Zahavi, A. (1977, may). Reliability in communication systems and the evolution of altruism. En *Evolutionary ecology* (pp. 253–259). London: Macmillan Education UK. Descargado de <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=4983077>http://link.springer.com/10.1007/978-1-349-05226-4_{_}21 doi: 10.1007/978-1-349-05226-4_21



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS



Instituto de Investigación en Ciencias Básicas y Aplicadas



Cuernavaca, Morelos, 1 de febrero de 2024

**DRA. LINA ANDREA RIVILLAS ACEVEDO
COORDINADORA DEL POSGRADO EN CIENCIAS**

P R E S E N T E

Atendiendo a la solicitud para emitir DICTAMEN sobre la revisión de la tesis titulada: Evolución de señalización y altruismo en agentes artificiales, que presenta el alumno José Manuel Pardo Cruz (10021253) para obtener el título de **Doctor en Ciencias**.

Director de tesis: Dr. Bruno Lara Guzmán

Unidad Académica: Instituto de Investigación en Ciencias Básicas y Aplicadas (IICBA)

Nos permitimos informarle que nuestro voto es:

NOMBRE	DICTAMEN	FIRMA
Dr. Juan Manuel Rendón Mancha CInC-UAEM	APROBADO	
Dr. José Daniel Arzate Mena CInC-UAEM	APROBADO	
Dra. Verónica Mercedes Narváez Padilla CIDC-UAEM	APROBADO	
Dra. María Asela Reig Alamillo CINCCO - UAEM	APROBADO	
Dra. Alejandra Ciria Fernández Varela Facultad de Psicología, UNAM	APROBADO	
Dr. Alejandro Ángel Garcíarrubio Granados Instituto de Biotecnología - UNAM	APROBADO	
Dr. Bruno Lara Guzmán CInC-UAEM	APROBADO	





UNIVERSIDAD AUTÓNOMA DEL
ESTADO DE MORELOS

Se expide el presente documento firmado electrónicamente de conformidad con el ACUERDO GENERAL PARA LA CONTINUIDAD DEL FUNCIONAMIENTO DE LA UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MORELOS DURANTE LA EMERGENCIA SANITARIA PROVOCADA POR EL VIRUS SARS-COV2 (COVID-19) emitido el 27 de abril del 2020.

El presente documento cuenta con la firma electrónica UAEM del funcionario universitario competente, amparada por un certificado vigente a la fecha de su elaboración y es válido de conformidad con los LINEAMIENTOS EN MATERIA DE FIRMA ELECTRÓNICA PARA LA UNIVERSIDAD AUTÓNOMA DE ESTADO DE MORELOS emitidos el 13 de noviembre del 2019 mediante circular No. 32.

Sello electrónico

BRUNO LARA GUZMAN | Fecha:2024-02-06 16:25:04 | Firmante

L4DDaZSL6lzsCpjO0otlABZlpsWCAKwlsJmcjhCHlUnnsB8OXfK/ccEoCUECgnYsP5Eaxskl8+hhqoUbj3kV2JodthCCbnSH0uDcl4hzW/Jrd+kWFL4OcY77CCUDKe410Zji6f+9E4VRkGoGPgohzFu9BVeShFxcn2x8p4xETjvghJei5r1cbgiiRTFGaoNpXG9z8W55DRqOP9YtmclP4cyW2VEx+rflZkAmEEeBzU1lq2UCLB792xXxazbJ2dqtcZxxhrm+yqHAHWAEKd3mjMdaHYpB2orzW+erKwVwzzOJr/eoOV8y09OGIO3xasdAQf0wYO1peq8SSLN+WrxQ==

MARIA ASELA REIG ALAMILLO | Fecha:2024-02-06 16:50:22 | Firmante

PzXwboLwlrwkcE7o4XnoWtDQDwly9CQclW3EszS1JWs0dX1atuCixq7X6ONK8ZrHQrB5v64ResUMS2m/goSSmBbtRwk4zNsaqgkHf2mQQvi18/T41WmFHXJKZXvot+mE1WcxWeNjm612U1S3WLR0L/zfVTZDIQgqoaha+o8o+4Wt57TcnyZ0Azpew6goWyHsS67quip3XuMSvltNRUdpe61cwEPDBxVHndN1x/4ZOC2K3KCGmJ7UchgdUx1hbxHt2OO7F4oc/LzgwBmg0WnRq0QmH5fVE8CICfcmXnFR4EEBesU3cgKaWmfwZyTvicvjCklJ5ceTLnR+mYLsqCgA==

JUAN MANUEL RENDON MANCHA | Fecha:2024-02-06 18:31:36 | Firmante

e0k4SVItxnGtJdx/dzFKk8RDTqGBW100cx5ryhF4GWTmu+vjoR4IJDbGbyaLUshc3zuxsFP2Tx+8rhVLqtol4b40MumIU1EUC7278F0uhPQ+R/eCWddGyVmWiZ9Vik8SRCgXBBQKRskmL75HrIb0KU95XiAM7Y2tWb7yfkQRiv6vpaHfn5OqobG94RnkcECD9wdBnVDA5zArNSX+LRC0V3dc+6VtheSWv6cZTIMZdn5V679MnC7HDynO3YZYaBkSmWdkdTbC/K1yN8pnkioQLDZuooBciPmjaelJuv9f74YKn6CipifHsAmC60bA53WkG14OL6rdqVb2xjs/Vg==

ALEJANDRA CIRIA FERNÁNDEZ VARELA | Fecha:2024-02-06 19:50:03 | Firmante

EfXpVrV6yPHjXJZD43cr4t4U7DV5qCsNaxvxiUCx/iTb+9uR2D4VwI8TGLk3AmFpHakYbLp+lq1aW/y8M0PYUNY3IS6fqBMZ6jzfcifkI9kZ8I3rTs9uuHswBLKPs4Rntp9Rze3NDZw/Zp1kikJd1VsTgmC+Tpbip4jdbDI0ynvHWEVqqh2XUYahaW649a2Ojbspvb/U0a1OxOlmkONpJ+pou+YdJieS2yccszvYerADBwTSoVDqybkEchKzq+Jf1Z52bY/E/RaBqpsZ3A9e+nDeGPW3DKq4yWmVGG6pOOBPsD/DGGe+y7qxZjsV28NEr5+dqDqZ3zfe2diphQ==

ALEJANDRO GARCARRUBIO | Fecha:2024-02-06 20:22:18 | Firmante

Riuww4BM/9o2Ww2syrK6etDldCDyUzE8TRbM/cVsrDClmqEsoUk5LijzFqL5X2J1fnZ/SOPpLlySGmJacgaVRnL2JZyByq4A07yDFL5smPuThxqMp7HkbCAQK/frWHfHrNeZCN44kAnnT7sX92Sd8LV1z9pvgOSvHG+hj2OOSHnDLcENUtRT0j1jLJzGca2nEfwkO+ljax5a/ua73wKkQz8uh3j5AGW0LwoumwpTs093mxd/vod7+m6CA1XEokfbXwEjSjn1HyfwUIrQgn+62P6S+Ecpd22pHAzySgudjuyyieT8vl6dbZ6U7/2GIBUtpN9EmbzwmirDaEirkg==

JOSÉ DANIEL ARZATE MENA | Fecha:2024-02-06 20:33:20 | Firmante

356v+4RMInC78xWZiYlw7/zTaz29pbnwSni5A11qp6p49eBO5E538tp0DHHAG1C5MOH0QQDnzk/DTxfRDO7Eb7Dks1DG+5U8qERhUGmLPxqOisZB8/3M7d0xeO6SmlXfGGV814hy5nP0vRV4vcmiRJAep1xqJwbWz8QPcWaA571pVzSUAcv8sOe3UepyW+IEhRsoJn4Q7+ZgC1H6TB0dZ8Eg5IMRduputrm9/qfmsYSBwCymImdvi7eHSVZHeA3mLWvIWlpnAgG/HzfZZhimyHTJUprR2QJbJxobHbbzTnFUDBM2kC1s1dH6jOmZUVIrlLoe3ybxTR5ajEbVxzYg==

VERONICA MERCEDES NARVAEZ PADILLA | Fecha:2024-02-06 20:39:51 | Firmante

ZdnW897wBNpOGVJB7ClqJ+A+wlcPt7psdqXQ7kNPwZLCRwHrGX6+eXkUOVYWWlZCGcJEh0q1RhYp9cHRDXJ/tj44LY8BuAyVu8v1H/s9tGJv14OO7wUzh2m6lBfCnlMtoJAydHfQ2ne+TmuUnVx998oAOA5MeBu/jtfm1y8hkjZso0KN7qclTKyZj0S4A17CF+AVcVXdbRU1KUa7jH+P2OnGtZDgl0WRV8ppFV3eHc6geQVFTEX18PASTBqleRe7Wc/GJdvVxDeSPIG4SmeWxTAsGJEVA9LvCon40LmhMoQlwJVQogS7QvU387WcAnGMI/yJfCdPpE4K89w==

Puede verificar la autenticidad del documento en la siguiente dirección electrónica o escaneando el código QR ingresando la siguiente clave:



w0vQNURIZ

<https://efirma.uaem.mx/noRepudio/aaMI0yzkW0TDQoEHgbnZGoLGE0kzbT3L>



UAEM
RECTORÍA
2023-2029