

Evolución de señalización y altruismo en agentes artificiales

José Manuel Pardo Cruz

12 de junio de 2019

1. Introducción

En este trabajo intentaremos mostrar si la robótica evolutiva se presenta como una herramienta eficaz, para el estudio de los procesos evolutivos que conducen al surgimiento de habilidades cognitivas en organismos biológicos, para ello modelaremos dichos procesos utilizando algoritmos evolutivos y redes neuronales artificiales en agentes autónomos simulados.

Nos centraremos en casos que han resultado particularmente difíciles de tratar para la robótica evolutiva, como lo son el surgimiento del altruismo y la comunicación; intentaremos encontrar las condiciones mínimas necesarias para que las conductas de señalización y altruismo surjan, modelando procesos propios de la evolución en agentes artificiales simulados, lo cual podría a largo plazo permitirnos plantear una analogía con su surgimiento en agentes biológicos.

2. Objetivos y preguntas de investigación

Encontrar las condiciones mínimas necesarias que deben ser modeladas para el surgimiento de conductas de comunicación y altruismo en agentes artificiales, usando los principios de la teoría evolutiva. Así como explorar si este tipo de modelado da como resultado soluciones menos reactivas por parte de los agentes artificiales al intentar resolver un problema. Con lo cual surgen 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?
- ¿Cuales son las condiciones mínimas que deben ser modeladas para este propósito?
- ¿Podemos estudiar procesos cognitivos usando estas herramientas?
- ¿Este tipo de modelado puede ayudar a generar conductas menos reactivas en agentes artificiales?

3. Que entendemos por robótica evolutiva

Partiremos en este trabajo de una definición amplia de «robótica evolutiva», la cual incluye diversos métodos inspirados en los principios que rigen la evolución de los agentes biológicos, enmarcando la investigación como lo hace [Bongard \(2013\)](#) dentro de la cognición corporeizada que enfatiza la importancia del cuerpo de los agentes para el surgimiento de procesos cognitivos.

Así la robótica evolutiva consistiría en el modelado del aprendizaje y/o la creación de agentes artificiales, físicos o simulados, a través del uso de principios propios de la teoría sintética de la evolución, con la intención de que dichos agentes artificiales sean capaces de aprender con mínima intervención humana, conductas que les permitan actuar de forma exitosa en el medio ambiente en el cual fueron evolucionados ([Nolfi y Floreano, 2000](#); [Doncieux y cols., 2015](#)).

Entre los más importantes utilizados por la robótica evolutiva se encuentran los algoritmos genéticos, los algoritmos evolutivos y la vida artificial. Los cuales han sido utilizados tanto para estudiar la cognición como resolver problemas de tipo ingenieril.

Si bien existen críticas realizadas a la robótica evolutiva como herramienta de estudio de los procesos cognitivos y del proceso evolutivo en general, se ha señalado que los procesos biológicos modelados en la robótica se encuentran sobre simplificados ([Doncieux y cols., 2015](#)), con lo cual, sería poco lo que nos pueden decir sobre la evolución y cognición de los agentes biológicos, sin embargo, esta crítica aunque acertada en sus premisas, no es tan relevante como se puede suponer a primera vista pues partimos de la premisa según la cual la evolución es un proceso independiente del sustrato en el que esta ocurre, lo que significa que la evolución sucederá siempre que se cumplan tres requisitos básicos: Reproducción, variación y competencia ([Dennett, 2002](#)). Por otra parte creemos al igual que [Cliff y cols. \(1993\)](#) que los problemas que debe de resolver un agente artificial autónomo, no distan demasiado de aquellos que enfrentan sus contrapartes biológicas.

En este sentido se ha mostrado que aun las formas más abstractas de modelado de los procesos evolutivos como los algoritmos genéticos, los cuales modelan de forma muy simple los procesos de selección natural, reproducción y mutación¹, pueden generar buenas soluciones a problemas de alta complejidad usando redes neuronales artificiales sencillas.

Lo anterior se pone de manifiesto en los múltiples trabajos presentados por [Floreano y Keller \(2010\)](#), donde a pesar de utilizar algoritmos genéticos en su forma más “básica”, en los cuales los genomas de cada individuo están mapeado uno a uno en los pesos de las conexiones de una red neuronal artificial, y, no se modelan interacciones entre los genes, desarrollo durante la ontogenia, disparos neuronales, o el tiempo. Logran sin embargo evolucionar fenómenos tales como: Evasión de obstáculos, la capacidad por parte de un agente artificial de encontrar su madriguera, dinámicas de co-evolución presa/depredador, así como conductas de cooperación, el surgimiento de comunicación entre agentes, y, la capacidad de distinguir entre comida y veneno ([Floreano y cols., 2007](#)), logrando que estos

¹Todo esto mediante la simple representación de los «genes» en cadenas binarias, cada uno de las cuales están mapeadas directamente a una expresión fenotípica, siendo esta expresión por lo general el peso en la conexión entre dos neuronas de una red neuronal artificial

comportamientos evolucionen en tan solo unos cuantos 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, puede ser rastreada al menos a los trabajos de Brooks (1991), el cual en el marco de la cognición corporeizada muestra que una vez que asumimos que “el mundo es el mejor modelo de si mismo”, las conductas de al menos organismos con poca complejidad, pueden ser modeladas de una forma mucho más sencilla de la que había sido asumida por la inteligencia artificial hasta ese momento, lanzando 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.

Por otra parte este esfuerzo por usar a la robótica evolutiva como herramienta para el estudio de la evolución y de los procesos cognitivos, ha llevado al intento de trabajar con modelos mucho más completos que intentan incluir cada vez más de las complejas interacciones que se dan en la evolución de agentes biológicos (Banzhaf y cols., 2006) por mencionar algunos: Evolucionar no solo el controlador de los agentes artificiales sino coevolucionar al mismo tiempo su morfología (Sims, 1994; Cheney y cols., 2016; Bernatskiy y Bongard, 2018); simular redes neuronales capaces de aumentar su complejidad a través del proceso evolutivo conocidas como NEAT «Neuro Evolution of Augmenting Topologies» (Stanley y cols., 2002); 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); el uso de operadores epigenéticos en la expresión fenotípica de agentes artificiales simulados y físicos (Brawer y cols., 2017)

Por último como señala Harvey y cols. (2005), aunque es cierto existe esta sobre simplificación; cuando se estudian procesos cognitivos o evolutivos en agentes artificiales, no se pretende que los resultados obtenidos sean dados de forma inmediata como válidos también en agentes biológicos, sino, usarlos como una herramienta que nos permita conocer las condiciones mínimas necesarias para que la evolución de cierto proceso cognitivo se produzca, y en caso de ser posible, someter dichas conclusiones a prueba en agentes biológicos.

3.1. 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 pretendan explicar cierto fenómeno o capacidad cognitiva presente en los agentes biológicos y que sea extremadamente difícil o imposible someter a prueba en los mismos, ya que si bien es cierto que se llevan a cabo experimentos de evolución en agentes biológicos en lo que ahora se conoce como “evolución experimental” (Kawecki y cols., 2012), estos presentan sus propios inconvenientes, como el hecho de resultar prohibitivos en términos temporales, aun los experimentos hechos con organismos con un ciclo de vida relativamente corto como las bacterias, toman años en su realización.

Tomemos por ejemplo los famosos experimentos realizados por [Lenski y cols. \(1991\)](#) que estudian la evolución y mide la aptitud (capacidad reproductiva de la población de bacterias en ambientes con pocos nutrientes disponibles) de 12 poblaciones de *E. coli* cultivadas en laboratorio, en un ciclo de reproducción de 40 mil a 50 mil generaciones, este estudio tomo más de una década para su realización. Con lo cual se pone en evidencia que fenómenos que se presentan en organismos con un ciclo de vida más largo que el de las bacterias, que son justamente donde podríamos estudiar cuestiones como el surgimiento de la señalización y el desarrollo de la comunicación a través del proceso evolutivo, simplemente serían inviábiles.

Otro problema que nos encontramos al intentar estudiar este tipo de fenómenos, es que las técnicas tradicionalmente utilizadas para el estudio del surgimiento de ciertas capacidades, como acudir al registro fósil, no pueden aplicarse en estos casos porque como señala [Vonk y Aradhya \(2015\)](#) las habilidades cognitivas no se fosilizan. En cambio tenemos ejemplos provenientes de la robótica evolutiva como los experimentos llevados a acabo por [Floreano y cols. \(2007\)](#) donde se estudia de forma experimental el surgimiento de la comunicación en agentes artificiales mediante el proceso evolutivo, o los diversos estudios que analizan el surgimiento y estructura del lenguaje desde la robótica evolutiva ([Steels, 2003](#)).

Otra de las cualidades de la robótica evolutiva como herramienta de investigación, es que nos permite no solo observar el proceso evolutivo sino intervenir en formas en las cuales sería imposible hacerlo en agentes biológicos, por ejemplo: Podemos volver a cualquier punto de la evolución de cierto agente artificial; modificar las condiciones de su ambiente, así como las presiones de selección; eliminar de forma artificial cierto genoma de la población para estimular el surgimiento de nuevas soluciones a un mismo problema, o, como lo hace [Stanley y Miikkulainen \(2004\)](#) forzar la especiación dentro del pool genético que estamos evolucionando, para fomentar el surgimiento de soluciones más novedosas, complejas y/o eficaces a un problema, o por el contrario analizar cuales son las condiciones mínimas necesarias para que la especiación suceda de forma no forzada en agentes artificiales.

3.2. Problemas abiertos

Existen sin embargo algunos problemas que la robótica evolutiva aun no ha podido resolver de forma contundente, presentare aquí unicamente dos de los más representativos. Estos son el problema de la escalabilidad y de la evolucionabilidad.

3.2.1. Problema de la escalabilidad

El primero de ellos es la falta de escalabilidad de las habilidades cognitivas de los agentes artificiales. En diversas investigaciones se ha señalado que la robótica evolutiva suele generar soluciones de tipo reactivo en lugar de soluciones de tipo cognitivo ([Lehman y Miikkulainen, 2014](#)), por ejemplo que las redes neuronales evolucionadas para resolver un problema de evasión tengan un comportamiento muy similar al de robots meramente reactivos como los

braitenberg ² (Braitenberg, 1986), en lugar de un comportamiento de evasión mucho más sofisticado. Desde nuestra perspectiva el problema de la escalabilidad puede deberse a varias razones:

La primera es que como en el caso de la evasión de obstáculos, la tarea a ser resuelta no requiere de soluciones creativas, y, en este sentido el algoritmo evolutivo efectivamente ha convergido en una solución muy cercana a la óptima, pues la evolución por selección natural es “ciega” ya que no le importa si la solución es reactiva o cognitiva, siempre que permita una mejora en la aptitud del agente.

La segunda, como señala el mismo Lehman y Miikkulainen (2014) es que normalmente los mecanismos cognitivos complejos requieren de la suma de varios mecanismos; los cuales son resultado de diversas mutaciones que se tienen que ir sumando con el tiempo para ser útiles en la resolución de un problema, esto último no sucede fácilmente en el caso de los algoritmos evolutivos.

Por último nosotros consideramos que puede deberse a que quizá desconocemos aun los mecanismos más allá de la selección natural, que deben ser modelados en agentes artificiales para permitir el surgimiento de soluciones sofisticadas o creativas.

3.2.2. Problema de la evolucionabilidad

Lo anterior se relaciona profundamente con el segundo problema que nos gustaría abordar conocido como el problema de la evolucionabilidad. Aunque hay cierta discusión tanto en el área de la robótica evolutiva como en de la biología sobre lo que se entiende como evolucionabilidad (Pigliucci, 2008; Lehman y cols., 2016; Wilder y Stanley, 2015), nosotros optaremos por la definición dada por Lehman y cols. (2016), la cual señala que en términos generales se trata de la capacidad de un algoritmo evolutivo de hacer que su población se mueva a través del espacio de solución del mismo de una forma eficaz, logrando así el surgimiento de nuevas soluciones o de comportamientos novedosos conforme van avanzando las generaciones del mismo.

Resolver este problema no ha sido tan fácil de lograr como se había pensado, debido a que una vez que un algoritmo evolutivo da con una solución a la tarea que el agente artificial debe resolver, dicho algoritmo se estanca en esta solución, aunque ésta pueda estar muy alejada de la solución óptima a dicho problema.

Entre los factores conocidos por los cuales esto ocurre, está el hecho de que una vez que un algoritmo da con una solución mediocre conocida como “máximo local”, el pool genético de la población converge rápidamente a través del proceso de selección en dicha solución, mientras que la mutación la cual se ha considerado como la forma de ampliar el espacio de búsqueda hacia nuevas soluciones, suele hacer que el agente que sufre esa mutación se aleje de ese máximo local, y, debido a que una de las características de los algoritmos evolutivos es que su espacio de solución suele ser extremadamente grande y las soluciones que resuelven dicho problema mucho menores en número a las que no lo resuelven, resulta mucho

²Vehículos con motores diferenciales propuestos en una serie de experimentos mentales por Valentino Braitenberg (Braitenberg, 1986), en los cuales muestra que se pueden generar conductas aparentemente complejas a partir de cablear directamente los distintos sensores de dicho vehículo a sus motores, el ejemplo más conocido es el caso del vehículo que él llama “2a” capaz de realizar evasión de obstáculos

más probable que el individuo que presenta una mutación drástica, presente un aptitud mucho más baja que aquellos que se han mantenido en la solución ya alcanzada, provocando que los genes este nuevo individuo se elimine del pool genético de la población.

3.3. ¿Cual es el inconveniente con las soluciones dadas a estos problemas?

Si bien hay intentos de solucionar estos problemas, desde nuestra perspectiva al menos algunos de ellos presentan fallos fundamentales. Suele darse el caso de que los investigadores intentan que estos procesos de evolucionabilidad y escalabilidad se den de forma forzada, a través de mecanismos que son ajenos a la teoría evolutiva y/o biológicamente poco plausibles.

Un ejemplo de esta clase de soluciones puede hallarse en los trabajos de [Stanley y cols. \(2002\)](#); [Lehman y Stanley \(2008\)](#); [Stanley y Miikkulainen \(2004\)](#) donde se genera la especiación de la población a través de mecanismos de búsqueda de novedad, que premian la aptitud de un individuo por el simple hecho de ser una solución novedosa, sin que esto parezca tener un fundamento en los procesos evolutivos conocidos, ni sea biológicamente plausible.

Si bien cierto que los mecanismos de búsqueda de novedad han mostrado mejor desempeño al afrontar estos problemas que los enfoques a través de métodos adaptativos ([Wilder y Stanley, 2015](#)), para nosotros de nada nos sirve forzar estos fenómenos si nuestro interés es entender como suceden estos procesos en los agentes biológicos. En este sentido consideramos que es importante volver a las preguntas que la biología y la robótica evolutiva comparten: *“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?”* ([Nolfi y Floreano, 2000](#)) y en este sentido nos parece central encontrar cuales son estas características claves de las que habla [Nolfi y Floreano \(2000\)](#) e intentar modelarlas.

4. Propuesta de trabajo

Desde esta perspectiva resulta interesante utilizar lo mejor de las dos formas aquí delineadas de hacer robótica evolutiva. Por un lado mantener modelos mínimos como los planteados por [Floreano y Keller \(2010\)](#); [Floreano y cols. \(2007\)](#) que nos permitan estudiar el proceso cognitivo deseado, mientras por otra parte resulta fundamental tomar en cuenta que ciertos procesos cognitivos dependen de otros factores distintos a la selección natural, en ese sentido es necesario analizar y probar cuales son estos factores para cada caso particular, modelando dichos factores para su estudio.

Con el objetivo de mantener el modelado en un nivel relativamente simple usaremos algoritmos genéticos y redes neuronales artificiales, para controlar agentes artificiales en un entorno simulado, usando el simulador Enki ([Magenat y cols., s.f.](#)), ya que existe extensos ejemplos del uso de estas métodos de manera exitosa en el modelado de tareas complejas ([Harvey y cols., 1997](#); [Bongard, 2013](#); [Cliff y cols., 1993](#)).

4.1. Algoritmos genéticos

Los algoritmos genéticos (**AG**) modelan de forma abstracta los procesos de la teoría sintética de la evolución y fueron pensados como un método para encontrar soluciones eficaces a problemas de optimización y diseño (Banzhaf y cols., 2006; Holland, 1975) cuya solución ideal se desconoce o resulta demasiado difícil de programar de forma predeterminada. Los algoritmos genéticos resultan un método ideal en estos casos debido a que; pueden encontrar en un tiempo razonable una buena solución a un problema dentro de un espacio de solución extremadamente grande. Esta es una de las razones por las cuales son una de las técnicas más utilizadas en la inteligencia artificial y la más utilizada en 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 (**figura 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.

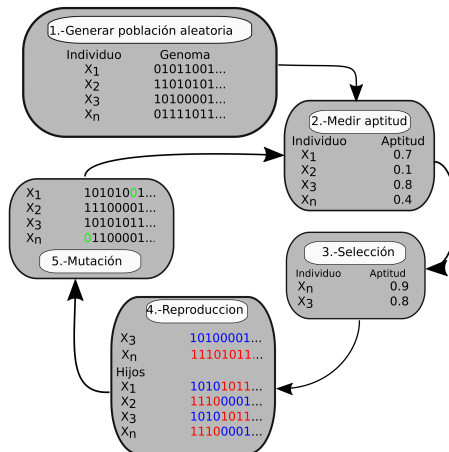


Figura 1: Representación esquemática de un algoritmo genético.

Los algoritmos genéticos representan la información de cada individuo en un genoma el cual funciona como un análogo del ADN de los organismos biológicos, existen múltiples formas en las cuales se puede representar la información de un individuo en un algoritmo genético; números reales, números enteros, conductas pre-programadas. El método más extendido es el uso de una cadena de números binarios, constituida por segmentos de cierta longitud, cada uno de los cuales sería el análogo a un gen y la expresión fenotípica de dicho gen es un número real, dichos números funcionan como el peso de una de las conexiones de la red

neuronal artificial del individuo al cual pertenecen (**figura 2**). El hecho de que se prefiera el uso de números binarios como método de representación se debe a que está demostrado que ofrecen una mayor explorabilidad³ del espacio de solución que otro tipo de representaciones utilizadas (Coello, 2004).

4.2. Definición de términos

Antes de proceder a explicar porque decidimos modelar la señalización y altruismo me parece importante aclarar las definiciones que adoptaremos de dichos términos y algunos relacionados con las tareas a modelar; señalización, señal confiable, señal engañosa, efecto de la barba verde y altruismo.

Señalización En el caso de la la señalización partiremos de la definición de señal dada por (Otte, 1974) “*Signals are defined as behavioral, physiological, or morphological characteristics fashioned or maintained by natural selection because they convey information to other organisms*”. 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 aquellas transmisiones de información que cierto organismo puede transmitir debido a sus propiedades a otro, 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 las teorías de como pudo surgir la señalización; por ritualización o coerción, pues 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 y cols., 2012).

Señal confiable y engañosa Cuando hablamos de confiabilidad y engaño en las señales debemos separarnos de cualquier idea de moralidad que los humanos asignan a estas conductas, pues como señala Searcy y Nowicki (2005) éstas en nada se relacionan a las interacciones que se dan en este nivel. Así hablaremos de una «señal confiable» cuando de hecho aquello que se señala, es decir la información que se transmite al otro agente, coincide con el estado del mundo y resulta beneficioso para el organismo que transmite la señal. Lo contrario ocurre cuando hablamos de las «señales engañosas», donde el emisor intenta abusar el sistema de comunicación, exagerando o transmitiendo información errónea sobre el estado del mundo en vista de obtener una ventaja en su aptitud al hacerlo (Scott-Phillips y cols., 2012).

Efecto de la barba verde Efecto de la barba verde (gen de la barba verde), se entiende como efecto de la barba verde a la expresión fenotípica de un gen, que de manera bastante llamativa sirve para indicar parentesco a otros miembros de la misma especie, es una idea propuesta por Dawkins (1976) y se ha encontrado de forma experimental la presencia de estos genes indicadores en al menos algunos tipos de hormigas (Keller y Ross, 1998), algunos tipos de bacterias (Queller,

³Es decir evitan que el algoritmo converja de forma prematura en un máximo local

2003) y existe evidencia que sugiere su existencia en mamíferos (Summers y Crespi, 2005).

Altruismo Por último hablaremos de altruismo retomando la definición utilizada por Floreano y cols. (2008) que estipula que el altruismo es aquella conducta de cooperación que tiene un costo a la aptitud (eficiencia reproductiva) de aquél que realiza la conducta. Es importante distinguir el altruismo de la cooperación, en la cooperación, si bien existe la conducta de ayudar a otro individuo, ésta se da debido a que el individuo que proporciona dicha ayuda o cooperación obtiene una ganancia al realizarla, y está demostrado que la cooperación es una estrategia evolutivamente estable en ausencia de altruismo usando el dilema del prisionero y simulaciones computarizadas (Axelrod y Hamilton, 1981).

4.3. ¿Por qué modelar señalización y altruismo?

La inspiración a este trabajo se encuentra en los experimentos realizados por el laboratorio de Dario Floreano (Floreano y cols., 2007, 2008; Mitri y cols., 2009; Floreano y Keller, 2010). Todos ellos guardan una estructura similar, en los cuales se intenta evolucionar de forma emergente la comunicación en agentes artificiales, mediante el uso de algoritmos evolutivos. En sus experimentos se usa un entorno simulado donde existen dos comederos, uno con alimento y otro con veneno, ambos con una fuente de luz roja que permite a los robots encontrarlos, la tarea es realizada por grupo de 10 robots móviles, capaces de emitir luz azul. La tarea de los robots es encontrar la fuente de comida y evitar el veneno, la aptitud de cada uno de ellos se mide 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 logren aprender que la luz azul es un indicador de la presencia de alimento, sin que la conducta de señalización o de seguir la luz sea premiada explícitamente por el algoritmo evolutivo. Ésto según los autores, 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; sin embargo a pesar de la gran relevancia de estos experimentos. Vale la pena volver a estudiar el problema del altruismo en agentes artificiales, porque si bien existen modelos matemáticos que explican su surgimiento en agentes biológicos: Selección por parentesco, selección de grupo, reciprocidad directa, redes de reciprocidad, reciprocidad indirecta (Nowak, 2006), y simulaciones que muestran que de forma idealizada estos modelos funcionan.

Ninguno de los trabajos realizados dentro del área de la robótica evolutiva como podemos ver el **cuadro 1**, ha logrado hacer surgir dicha conducta usando grupos de robots que no sean genéticamente iguales, a las cuales llamare 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 modelado de emisión de señales, es un acierto

Artículo	Evolución de altruismo en agentes artificiales						
	Tipo de poblaciones	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 y selección de grupo	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 de 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	Si	Red neuronal artificial	Sí	No	No aplica	Sí en poblaciones homogéneas
Floreano y cols. (2008) (experimento 2)	Heterogéneas y homogéneas	Si	Red neuronal artificial	Sí	Sí	Sí en poblaciones homogéneas y selección de grupo	Sí en poblaciones homogéneas y selección de grupo
Waibel y cols. (2011)	Parcialmente homogéneas	Si	Red neuronal artificial	Sí	No	No aplica	Sí
Palacios-leyva y cols. (2017)	Heterogéneas y homogéneas	Si	Red neuronal artificial	Sí	Sí	Sí en poblaciones homogéneas	Sí en poblaciones homogéneas
Palacios-leyva y cols. (2017)	Heterogéneas y homogéneas	Si	Red neuronal artificial	Sí	Sí	Sí en poblaciones homogéneas	Sí en poblaciones homogéneas

Cuadro 1: Artículos relacionados

por parte del equipo de investigación de Floreano (Floreano y cols., 2007, 2008; Mitri y cols., 2009; Floreano y Keller, 2010), y es algo que nos gustaría mantener en nuestros estudios. Las razones de esta afirmación son:

1. La habilidad de señalar es una argucia 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, electrorrecepción, tacto, oído y vibraciones (Endler, 1993; Cocroft y Rodríguez, 2005).
2. Se encuentran presentes en todos los tipos de organismos biológicos existentes Padje y cols. (2016)
3. La señalización de comida es una de las conductas de señalización más confiables existentes en los organismos biológicos

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

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

- Se abusa de las señales de advertencia de especies venenosas mediante el mimetismo batesiano (Pfennig y cols., 2001).
- Las señales de alarma que 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 las llamadas para señalar que se ha encontrado comida ya sean para compartirla, reclamar su propiedad o buscar apoyo del grupo, son extremadamente confiables Searcy y Nowicki (2005); Wauters y cols. (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.

Si bien existen casos específicos de engaño en el uso de estas señales para atraer hembras, esta es una dinámica que no se daría en un algoritmo evolutivo al no modelar el cortejo, ni la selección sexual. Así la confiabilidad de la señal vuelve más fácil su análisis, y, el hecho de que la señalización de comida incluya directa o indirectamente un costo a la aptitud del individuo, la hace también ideal para estudiar el fenómeno del altruismo. Todo lo anterior nos hace pensar que es posible estudiar las condiciones mínimas para su surgimiento del altruismo, de manera eficiente.

4.3.2. Propuesta experimental

Tenemos la convicción de que agregando al modelado, la relación genética de los individuos inspirándonos en el modelo de la barba verde y de la selección por parentesco propuesta por Hamilton (1963) donde establece un modelo matemático, conocido como la regla de Hamilton (**formula 1**). La cual establece que si el parentesco del individuo que realiza una acción altruista y aquel que

la recibe, multiplicado por el beneficio que recibe el destinatario de la acción, menos el costo que representa la acción altruista para aquel que la realiza, da como resultado un valor mayor que 0, entonces el altruismo es una estrategia evolutivamente estable en esa población.

Si esto también aplica en agentes artificiales, entonces lograremos encontrar el surgimiento de conductas altruistas en poblaciones con un pool genético heterogéneo, a diferencia de los trabajos de [Floreano y cols. \(2007, 2008\)](#); [Floreano y Keller \(2010\)](#) que solo consiguen evolucionar estas conductas en grupos de clones y no miden el efecto que tienen diversas proporciones de parentesco entre los individuos para decidir si ser o no altruistas con el otro.

$$RB - C > 0 \tag{1}$$

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 ([Floreano y cols., 2007, 2008](#); [Floreano y Keller, 2010](#)), usando como ya hemos dicho algoritmos genéticos y redes neuronales artificiales.

La idea de estos 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.

5. Experimentos

5.1. Evolución de altruismo informando a los robots de su parentesco

Este primer conjunto de experimentos, tiene el propósito de determinar si para evolucionar la conducta altruista en los robots, basta con que estos conozcan de alguna forma el parentesco que mantienen con los individuos que interactúan, como propone [Hamilton \(1963\)](#). Para ello informaremos directamente a cada individuo del parentesco que mantienen con el resto de los individuos que estén interactuando en determinado momento. El grado de parentesco se determinará usando la distancia hamming entre los genomas de cada uno de los dos individuos, y, se normalizara para producir un valor entre 0 y 1.

5.1.1. Entorno y robots

Los robots cuentan 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 permitirá a los robots emitir luz azul. Cada uno de los robots estará controlado por una red neuronal artificial, con una capa de entrada de 8 neuronas y una capa de salida de 3 neuronas (**figura 3**) cada neurona de la red tendrá 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, devolviendo valores de entre -1 y 1.

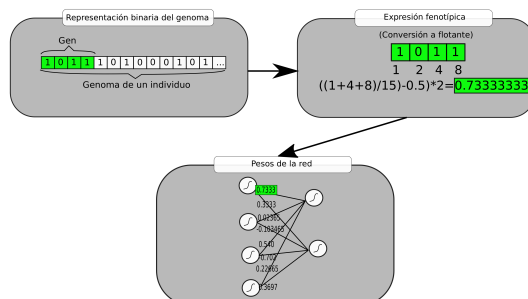


Figura 2: Esquema de la representación de un individuo en un algoritmo genético y la expresión fenotípica de sus genes como peso de una red neuronal.

Las primeras 6 neuronas de la capa de entrada percibirán cada una la presencia de luz azul correspondiente a 60 grados del campo visual del robot, para un total de 360 grados. La séptima neurona recibe el valor de la cámara de piso el cual será de 1 cuando el robot se encuentre sobre región con comida y 0 cuando se encuentre en cualquier otra zona del entorno, la última neurona de la capa de entrada recibirá el parentesco que dicho robot tiene con el otro robot presente en el entorno, el peso de cada una de las conexiones de la red podrá variar entre 1 y -1 esto permite que puedan existir conexiones que aumenten o supriman la actividad de una neurona, el valor de dichas conexiones está determinado por los genomas de cada individuo.

La capa de salida cuenta con una neurona para controlar cada uno de los motores y su valor de salida se normaliza de -15 a 15 para obtener la velocidad de los motores. Es importante señalar que para facilitar la realización de la tarea hemos decidido que las salidas de ambos motores tomen un valor igual a 0 cuando el robot se encuentre sobre la región de interés, por último, la tercera neurona controlará la emisión de luz azul, valores de salida superiores a 0 encenderá el anillo de leds y los menores a 0 lo apagarán.




Figura 3: Red neuronal artificial que controlará 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.




Figura 4: Entorno en donde se llevaran a cabo las simulaciones, en gris la región de interés, en verde los robots epuck

El entorno simulado tiene un tamaño de $2 m^2$ y cuenta con una región de interés delimitada por un círculo gris de $30 cm$ de diámetro ubicado justo al centro del entorno, esta región de interés representa una fuente de comida, la aptitud del robot estará directamente relacionada al tiempo que esté pase sobre dicha región.

En cada una de las simulaciones con duración de 1200 ciclos, se colocaran a dos individuos en el entorno, el primero de ellos se colocara justo en el centro del mapa dentro de la región de interés, mientras que el segundo aparece en una orientación y posición aleatoria (**ver figura 4**), la idea es que la única forma en la que el robot que aparece en una posición aleatoria sepa donde esta el alimento, es que el robot en la posición central lo señalice emitiendo luz azul con su anillo de leds.

Esta conducta de emitir luz cuando se esta sobre la región de interés es lo que consideraremos como una conducta altruista, ya que señalar la región de interés permite 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.

Es importante señalar que todos los robots de una generación tomaran ambos roles junto a cada uno de sus compañeros, así cada robot perteneciente a una generación participara en 98 simulaciones de 1200 ciclos cada una, 49 donde serán el robot que aparece al centro de la arena, y, 49 donde serán el robot que aparece en un sitio aleatorio.

5.1.2. Variables durante el proceso de evolución

El proceso evolutivo se utilizara para evolucionar los pesos de las conexiones de la red neuronal artificial encargada de controlar a los robots (**ver figura 3**). Cada uno de los procesos evolutivos tendrá poblaciones de 50 individuos por generación, y, se iterara durante 250 generaciones. Los individuos pertenecientes

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

Cuadro 2: Condiciones de evolución

	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 3: Variación de beneficio y costo en relación a la cantidad de comida

a una nueva generación tendrá una probabilidad de mutación de 1.8% es decir cada uno de los números que componen su genoma tendrán 1.8% de probabilidad de cambiar de cero a uno y viceversa, la cantidad de comida presente en la región de interés durante cada ciclo será la variable a modificar en cada proceso evolutivo, está tendrá valores que irán desde de 1 a 2 con variaciones de 0.2 para cada condición (**ver cuadro 2**), cada una de las simulaciones durara 1200 ciclos de 0.5 milisegundos. Para minimizar los efectos del azar en los resultados finales del proceso evolutivo, se evolucionaran de forma independiente 4 poblaciones por cada condición.

La función de aptitud que elegimos (**ver formula 2**), esta pensada de tal forma que cada robot que se encuentre sobre la región de interés, reciba una parte proporcional del alimento presente en dicha región, durante cada ciclo de la simulación. Sin embargo los robots no pueden recibir más de 1 unidad de alimento por ciclo, esto representa la cantidad máxima que un robot puede comer durante ese ciclo. Decidimos esto ya que como podemos ver en el **cuadro 3**, con solo variar la cantidad de comida en la región de interés podemos variar el beneficio y el costo de compartir el alimento con otro robot.

$$Aptitud\ Total = \sum_{i=0}^n (A_i = \begin{cases} (\frac{Nf_i * F}{RNf_i}) & \text{si } A_i < 1 \\ A_i = 1 & \text{en otro caso} \end{cases}) \quad (2)$$

Nf es 0 si el robot esta fuera de la región de interés y 1 si el robot se encuentra sobre ella, F la cantidad de comida que en la región de interés, y RNf la cantidad de robots en la región de interés, A la aptitud del robot durante un ciclo.

Una vez que todos los individuos de una generación hayan realizado todas sus simulaciones, usaremos un criterio de selección elitista, esto quiere decir que solo podrán reproducirse los individuos que cuenten con los mejores resultados según la función de aptitud antes descrita. La cantidad de individuos que podrán reproducirse sera el 50% de la población, una vez elegidos se formaran parejas de forma aleatoria, y, cada una de ellas producirá 4 hijos que pasaran a formar parte de la generación siguiente, esta cantidad permite mantener una población

Condiciones de la prueba								
Parentesco percibido		1	0.8	0.6	0.4	0.2	0	Costo
Beneficio	1	1	0.8	0.6	0.4	0.2	0	0
	0.9	0.8	0.62	0.44	0.26	0.08	-0.1	0.1
	0.8	0.6	0.44	0.28	0.12	-0.04	-0.2	0.2
	0.7	0.4	.26	0.12	-0.02	-0.16	-0.3	0.3
	0.6	0.2	0.08	-0.04	-0.16	-0.28	-0.4	0.4
	0.5	0	-0.1	-0.2	-0.3	-0.4	-0.5	0.5
$rb - c =$								

Cuadro 4: En este cuadro se puede ver como cambia el resultado de aplicar en cada una de las 36 condiciones de prueba

de 50 individuos a lo largo de todas las generaciones.

Lo que esperáramos dada nuestra función de aptitud y parámetros de evolución, es que los robots por una parte aprendan a encontrar la región de interés usando la única información disponible para ello, la cual es la emisión de luz azul del robot que ya se encuentra en dicha región. Por otra parte esperaríamos que dicha conducta de señalización disminuya o aumente en correlación a la cantidad de comida en la región de interés, y, al parentesco entre el robot que señala y el robot que recibe la señal.

6. Pruebas para determinar el nivel de altruismo

Dado que durante el proceso evolutivo no manipulamos el grado de parentesco de las poblaciones, y, que pueden surgir diversas estrategias para obtener un mejor desempeño en la tarea, es necesario una vez evolucionadas nuestras poblaciones de robots, realizar pruebas para determinar el grado de altruismo alcanzado por cada una de las poblaciones evolucionadas y que relación guarda esté con la cantidad de alimento disponible durante su evolución, así como con el grado de parentesco que presentan los individuos involucrados.

Pero antes de proceder con estas pruebas había que verificar que los individuos evolucionados en cada una de las condiciones antes descritas eran capaces de encontrar la comida, utilizando como único indicador la luz azul emitida por el otro robot, es decir que esta señalizaba la comida. Para verificar esto hicimos que los robots hicieran exactamente la misma tarea que durante el proceso evolutivo con la única diferencia de que el robot central siempre tenía la luz azul de su anillo de leds encendido, podemos ver en la **figura 5** que la inmensa mayoría de los robots logran llegar a la región de interés, mientras la **figura 6** nos muestra que parece haber una relación entre las condiciones de evolución y la dificultad con la que logran encontrar dicha región ya que a menor cantidad de alimento parece tomarles más tiempo encontrar la región de interés, esto muy probablemente debido a que los individuos que evolucionaron en condiciones donde había más alimento estuvieron expuesto en mayor medida a la emisión de luz azul.

Una vez comprobamos que los robots relacionaban la emisión de luz con

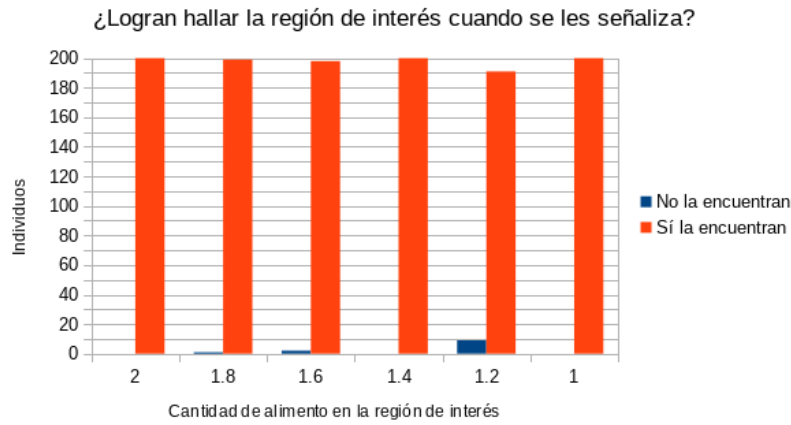


Figura 5: Cantidad de robots que lograron y no lograron llegar a la región de interés cuando está era señalizada (200 individuos totales para cada condición de evolución)




Figura 6: Tiempo que en promedio pasaron los 200 robots de cada condición en la región de interés cuando se les señala su posición, a la izquierda tomando en cuenta los dos roles; aparecer en el centro y en posición aleatoria, a la derecha cuando solo se considera las veces que apareció en un sitio aleatorio

la posición de la región de interés, realizamos un diseño experimental de dos factores, donde mediremos las poblaciones de robots evolucionadas con 6 diferentes niveles de comida, bajo 6 diferentes niveles de parentesco, conformaremos los grupos experimentales según la cantidad de alimento presente en la región de interés durante el proceso evolutivo(6 valores distintos), para cada uno de los cuales existe 4 grupos de 50 individuos (ya que se realizaron 4 procesos evolutivos por cada valor).

A cada uno de estos grupos lo volveremos a poner a prueba en el entorno donde evolucionaron (**figura 4**) y al igual que durante el proceso evolutivo cada individuo desempeñara el papel del robot que esta en el centro y el que aparece en una posición aleatoria de la arena con todos sus compañeros de generación, para un total de 98 simulaciones por individuo. Pero modificaremos de forma arbitraria el valor de parentesco que la red neuronal de los robots recibe en cada una de las pruebas, estos valores variaran de entre 0 a 1, para cada condición experimental, con un incremento de 0.2 en cada una de ellas. Todo esto para un total de 32 pruebas por nivel de mutación (**ver cuadro 5**).

Condiciones de la prueba						
Parentesco percibido	1	0.8	0.6	0.4	0.2	0
Cantidad de alimento	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
Grupos por condición	4					
individuos por grupo	50					
individuos por condición	200					

Cuadro 5: Condiciones de prueba

7. Resultados provisionales

Una vez realizados las pruebas notamos como podemos ver diagramas de dispersión (**ver figura 7**) que no existe una conducta de encendido o apagado del anillo de leds que sea constante a través de los individuos que evolucionaron bajo diversas o las mismas condiciones, sin embargo a diferencia de otros trabajos previos también notamos que al menos en las condiciones con una mayor de alimento en la región de interés y mayor parentesco una buena proporción de robots emitían luz dentro de la región de interés, lo cual ha sido definido como una conducta altruista.

Con el fin de determinar si dicha conducta altruista se relacionaba con el nivel de parentesco y la cantidad de comida, de cada grupo de 200 individuos evolucionados con distintas cantidades de alimento (6 en total), tomamos a los 40 individuos más altruistas y calculamos su promedio de emisión en la región de interés según el nivel de parentesco que percibían en el otro robot presente en la arena, y como podemos ver en la **figura 8**, parece que existe una correlación entre los niveles de altruismo del mismo individuo en relación al parentesco, como entre el altruismo y la cantidad de alimento disponible durante el proceso evolutivo.

Si bien es cierto que aun falta realizar el análisis estadístico de los datos, estos parecen indicar tres cosas importantes: La primera, es que es posible lograr el surgimiento de conductas altruistas en agentes artificiales mediante algoritmos evolutivos sin usar poblaciones homogenias, si se modela el parentesco y el gen de la barba verde. La segunda es que parece que está conducta altruista se ajusta de cierta forma al modelo propuesto por [Hamilton \(1963\)](#).

Si bien el modelo implementado en este conjunto de experimentos aun sufre de ser demasiado simplista, ya que nosotros indicamos de forma directa el parentesco a cada individuo, y, la red neuronal que controla a los robots recibe la información visual totalmente preprocesada, estos primeros experimentos nos dan claros indicios de hacia donde poder llevar esta investigación. Una vez hemos demostrado que el surgimiento del altruismo es posible modelando estos dos fenómenos, podemos incrementar la complejidad del modelo para acercar sus características un poco más a su contraparte biológica.

Uno de nuestros primeros intereses es que los robots sean capaces de establecer

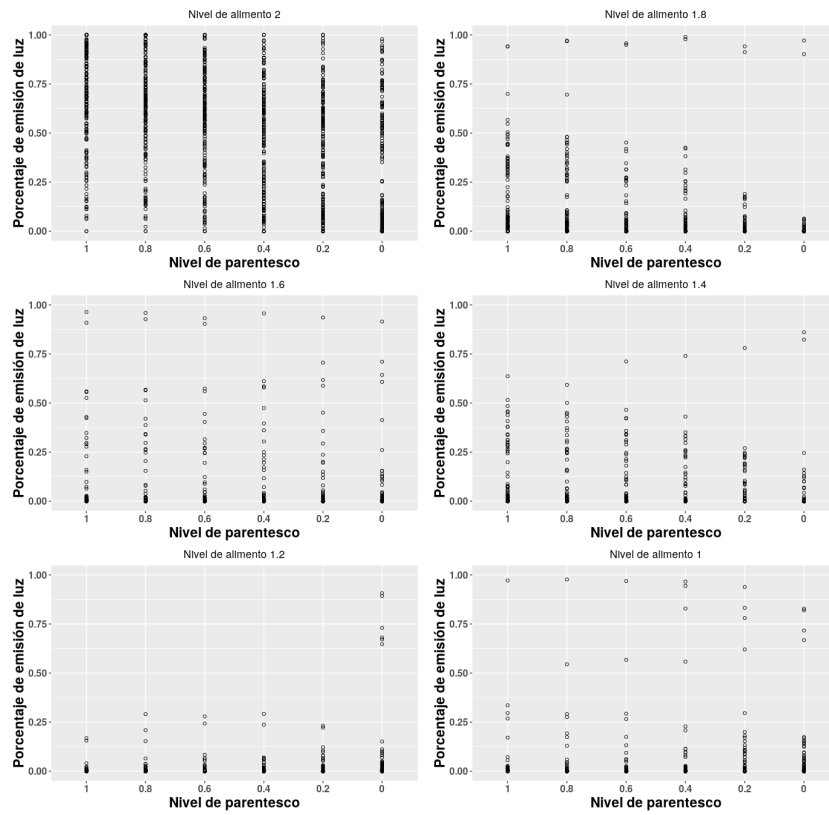


Figura 7: Nivel de emisión de luz dentro de la región de interés para todos los individuos evolucionados con distintas cantidades de alimento, según el nivel de parentesco que perciben en el otro robot

dicho parentesco a través de las características fenotípicas del otro robot, por ejemplo su color, lo que a su vez requeriría una red neuronal más compleja capaz de procesar estos estímulos visuales. Para esto una posibilidad sería mapear el genotipo de cada robot a un color determinado a través del uso de mapas auto organizados (SOMs) y usar este color de cada uno de los robots. Por último se puede ver un cronograma de actividades para el semestre próximo.

Cronograma de actividades					
2019-2					
	Agosto	Septiembre	Octubre	Noviembre	Diciembre
Análisis de los resultados	█				
Escribir artículo	█	█	█	█	
Diseñar experimentos		█	█		
Programar experimentos siguientes			█	█	█
Realizar simulaciones				█	█

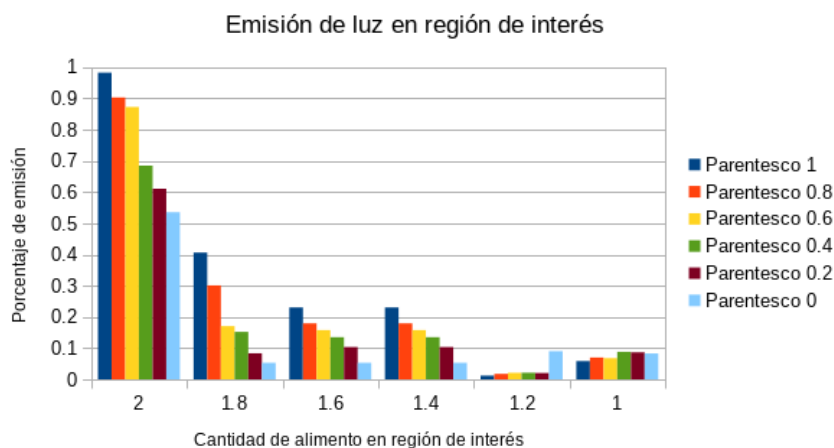


Figura 8: Nivel de emisión de luz dentro de la región de interés de los 40 individuos más altruistas evolucionados para cada cantidad de alimento

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?id=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
- 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](http://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., Sunspirai, 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:TBEOIV]2.0.CO;2
- Coello, C. A. C. (2004). Introducción a la Computación Evolutiva (Notas de Curso). (2508).
- Dawkins, R. (1976). The selfish gene: with a new introduction by the author. UK: Oxford University Press.(Originally published in 1976).
- 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-Urbe, 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

- 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
- Harvey, I., Husbands, P., Cliff, D., Thompson, a., y Jakobi, N. (1997). Evolutionary Robotics: the Sussex Approach. (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
- 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
- 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
- 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. (s.f.). Enki: The fast 2d robot simulator (2009). URL <http://lis.epfl.ch/resources/enki>.
- 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
- Nolfi, S., y Floreano, D. (2000). *Evolutionary Robotics: The Biology, Intelligence, 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 c. , 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
- 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

- 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
- 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 Hamilton’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
- 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