


eman ta zabal zazu



Universidad Euskal Herriko
del País Vasco Unibertsitatea

Departamento de Lenguajes y Sistemas Informáticos
Escuela Universitaria de Ingeniería de Vitoria-Gasteiz

NAVEGACIÓN MEDIANTE EVOLUCIÓN DE REDES NEURONALES RECURRENTES Y DINÁMICAS

Memoria de investigación presentada para optar al título de Doctor por
Pablo González Nalda

Directores

Blanca Cases Gutiérrez
y Álvaro Moreno Bergareche

San Sebastián, julio de 2008

NAVEGACIÓN MEDIANTE EVOLUCIÓN DE
REDES NEURONALES
RECURRENTES Y DINÁMICAS

*A mis padres: ellos son los que de verdad
han hecho posible esta tesis*



Agradecimientos

Primeramente, agradezco el trabajo que han realizado dirigiéndome la investigación los dos directores de esta tesis: Blanca Cases (departamento de Lenguajes y Sistemas Informáticos) y Álvaro Moreno (departamento de Lógica y Filosofía de la Ciencia).

Quiero también agradecer a Manuel Graña su colaboración para sacar adelante esta tesis. Igualmente a Julio Fernández Ostolaza y al grupo de Vida Artificial del departamento de Lógica y Filosofía de la Ciencia de la UPV/EHU por sus muy interesantes consejos y ayuda, y a Javier Dolado también por su apoyo. De la misma forma agradezco la ayuda de mis compañeros de departamento en Bilbao y Vitoria, especialmente a Bego Ferrero, Isma Etxeberria y Mari Carmen Otero.

No puedo olvidar en estos agradecimientos a dos colaboraciones fundamentales. Una fue realizada por Xabier Barandiaran, que puso toda su energía por echarme una mano y me proporcionó buenas observaciones. A Endika Bengoetxea le tengo que agradecer mucho: su ayuda y guía en esos momentos críticos y su predisposición para ayudarme en todo lo posible. Sin él habría sido más difícil.

Agradecimientos personales

Adolfo y Blanca, mis padres, saben todo lo que han hecho por mí y por mis hermanos. Estos, Roberto y César, también me han echado una mano con la Física y con las Matemáticas, que es lo suyo.

Gracias también a todas mis *ovejitas* (sobre todo Rubén y Kike) y a quienes en general me han sufrido todas las frases que empiezan por “*en cuanto acabe la tesis*”.



Índice general

Agradecimientos	VII
Índice general	IX
Resumen y organización de la memoria	XIII
Resumen	XIII
Organización	XIV
I Área de investigación y objetivos del trabajo	1
1 Análisis del área de investigación y objetivos del trabajo	3
1.1. Área de investigación: antecedentes y estado actual de la cuestión	4
1.2. Objetivos del trabajo	6
1.2.1. Obtención de un robot con un comportamiento de navegación en entornos no estructurados	7
1.2.2. Impulso de los objetivos técnicos de la Robótica Evolutiva	8
1.3. Problema implementado en la aplicación TOPOS	9
II Estado del Arte: Informática, Inteligencia Artificial y Robótica Evolutiva	13
2 De la Lógica a la Robótica Evolutiva	15
2.1. La Inteligencia Artificial y su relación con la Informática	15
2.2. Cerebros y máquinas	16
2.3. Conferencia de Dartmouth, Turing y Searle	16
2.4. La época dorada de la Inteligencia Artificial	18
2.4.1. Newell y Simon: la hipótesis del sistema de símbolos. El funcionalismo	18
2.4.2. Sistemas Expertos	18
2.4.3. Cierre de la vía de las Redes Neuronales	18
2.5. Crisis y resurgimiento de la Inteligencia Artificial	19

2.6.	El Conexionismo	19
2.7.	La Robótica en la Inteligencia Artificial	20
2.8.	Problemas fundamentales de la IA en la Robótica	21
2.9.	La revolución robótica	22
2.9.1.	Rodney Brooks. Corporeidad y ubicación	22
2.9.2.	Inspiración biológica: la Robótica basada en la Vida Artificial	23
2.9.3.	La <i>Caja de Skinner</i> y el concepto de Autonomía en la Vida Artificial	24
2.9.4.	Walter y Braitenberg	24
2.9.5.	Robótica Evolutiva	25
3	Análisis de la Robótica Evolutiva	27
3.1.	Objetivos y motivaciones específicos de la Robótica Evolutiva	27
3.2.	Situación actual de la Robótica Evolutiva	29
3.3.	Grupos básicos en Robótica Evolutiva	30
3.3.1.	John Koza	30
3.3.2.	Francesco Mondada y Dario Floreano	31
3.3.3.	Mototaka Suzuki	31
3.3.3.1.	Experimento y Red Neuronal	31
3.3.3.2.	Resultados	33
3.3.4.	Inman Harvey, Phil Husbands, Dave Cliff y Nick Jakobi	34
3.3.5.	Adrian Thompson, Phil Husbands e Inman Harvey	34
3.3.6.	Stefano Nolfi y Domenico Parisi	35
3.3.7.	Randall Beer y Brian Yamauchi	35
3.3.8.	Applied AI Systems, Inc. (AAI), Ottawa, Canadá	36
3.3.9.	Henrik Hautop Lund, Barbara Webb y John Hallam	36
3.3.10.	Trabajo en castellano	36
3.4.	Redes Neuronales	37
3.4.1.	Descripción matemática de las Redes Neuronales	38
3.4.2.	<i>Continuous Time Recurrent Neural Networks</i> (CTRNN)	39
3.4.3.	Redes Neuronales de Pulsos	39
3.5.	Algoritmos Genéticos	41
3.6.	Algoritmos Genéticos con Redes Neuronales en la RE	42
3.7.	La navegación en la Robótica Evolutiva	43
3.8.	Objetivos de los modelos en la Robótica Evolutiva	44
3.9.	Simulaciones y realizaciones en Robótica Evolutiva	44
3.9.1.	Sólo simulación	45
3.9.2.	Simulación y comprobación de los resultados en robot real	45
3.9.3.	Evolución exclusivamente en robots reales	45
3.9.4.	Conclusiones	46
3.10.	Límites y problemas de la Robótica Evolutiva	46
3.10.1.	La morfogénesis: evolución de la forma del robot	47
3.10.2.	El problema de la <i>escalabilidad</i>	48
III	La aplicación TOPOS: diseño, ejecuciones y análisis de resultados	49
4	Descripción de la simulación TOPOS	51
4.1.	Diseño general del modelo	51
4.1.1.	Fuentes de sonido o <i>faros</i>	52
4.1.2.	Individuos o <i>topos</i>	52
4.1.2.1.	Sensores	53
4.1.2.2.	Red neuronal	55
4.1.3.	Algoritmo genético	56
4.1.4.	Experimento y función de adecuación (<i>fitness</i>)	57
4.1.5.	Problemas del planteamiento incremental	57
4.1.6.	Evaluación de los individuos en las pruebas	58

4.2.	Descripción pormenorizada de los elementos del modelo	58
4.2.1.	Mundo	58
4.2.2.	Fuentes de sonido o <i>faros</i>	59
4.2.3.	Los individuos o <i>topos</i>	60
4.2.3.1.	Sensores	61
4.2.3.2.	Red Neuronal: neuronas y axones	61
4.2.4.	Pruebas	63
4.2.5.	Algoritmo Genético	63
5	Ejecuciones y resultados	65
5.1.	Experimentos que comprueban la corrección del sistema	66
5.2.	Eficacia de TOPOS en el reconocimiento de señales	68
5.2.1.	Reconocimiento de una determinada intensidad de señal	68
5.2.2.	Reconocimiento de una determinada secuencia temporal	69
5.3.	Robustez de los resultados frente al ruido	69
5.4.	Sonidos con partes de silencio	73
5.5.	Capacidad del sistema con sonidos PCM	73
6	Análisis de un individuo	79
6.1.	Objetivo y dificultades	79
6.2.	Proceso	80
IV	Conclusiones y trabajo futuro	87
7	Resultados globales, conclusiones y trabajo futuro	89
7.1.	Objetivos y resultados	89
7.1.1.	Desarrollo técnico en la Robótica Evolutiva	90
7.1.2.	Trabajo sobre algunos problemas de la Robótica Evolutiva	91
7.2.	Conclusiones y trabajo futuro	92
7.2.1.	Comparación con sistemas basados en visión	93
7.2.2.	Otras ramas modernas de la Robótica	94
V	Apéndices, bibliografía e índices	95
A	Gráficas del análisis de un individuo	97
B	El sonido y el oído. Psicoacústica	107
B.1.	Naturaleza del sonido	107
B.2.	Análisis de Fourier y espectro	108
B.3.	Medida del nivel de sonido: dB	109
B.4.	Linealidad	110
B.5.	Filtros	110
B.6.	Estructura y función básicas en el sistema auditivo	111
B.6.1.	Oído externo y medio	111
B.6.2.	Oído interno y membrana basilar	111
B.6.3.	El proceso de transducción y las células ciliares	112
B.6.4.	Respuesta del nervio auditivo	113
B.6.5.	Umbral y tasa de disparos espontáneos	113
B.6.6.	Sincronización de fase (<i>Phase locking</i>)	113
B.6.7.	Percepción del volumen	114
B.6.8.	Percepción espacial: Cono de confusión y papel de los movimientos de la cabeza	114
B.6.9.	Percepción espacial: Localización monoaural y la importancia del oído externo	114
B.7.	Ejemplo de activación neuronal	115
	Bibliografía	117

Glosario	125
Índice alfabético	129
Índice de figuras	133
Índice de tablas	137
Índice general	139



Resumen y organización de la memoria

Resumen

En este trabajo se diseña y construye una aplicación denominada TOPOS que, con los planteamientos de la Inteligencia Computacional, la Robótica en Entornos No Estructurados, la Robótica Evolutiva y la Robótica Bioinspirada, refleja los mecanismos biológicos con los que los seres vivos navegan en su entorno con el fin de evolucionar robots virtuales hasta obtener un comportamiento de navegación. Los robots virtuales obtenidos llevan a cabo de forma autónoma y adaptativa la extracción de características de señales muestreadas con el fin de usar dichas señales como puntos de referencia en la tarea de navegación. La extracción de características se realiza mediante evolución de sensores bioinspirados y de Redes Neuronales de Pulsos usando Algoritmos Genéticos para encontrar los parámetros adecuados que resuelven la tarea. La forma simétrica de los robots y su comportamiento de navegación a través de fonotaxias permiten el análisis como vehículos de Braitenberg generalizados.

En el entorno de simulación TOPOS un robot virtual desarrolla un comportamiento de navegación en un espacio bidimensional mediante la discriminación de sonidos. Las fuentes emisoras del sonido actúan como puntos de referencia en el comportamiento de navegación. La orientación a entornos no estructurados está dada por la naturaleza de los sonidos que empleamos: ruido, trozos de cantos de pájaro o de música de un CD, en lugar de señales simples. La señal recibida por el robot varía por su movimiento y posición y de forma independiente por la propia dinámica de la señal.

La principal aportación de esta tesis es utilizar el sonido no estructurado como referencia para la navegación de robots bioinspirados en lugar de usar señales visuales, que son totalmente direccionales. La aplicación TOPOS es innovadora ya que no se encuentran en la literatura trabajos sobre la extracción de características en sonido no estructurado, siendo los más próximos los relativos a la fonotaxia del grillo, que usan señales con una estructura concreta y se modela a mano el sistema auditivo del ser vivo.

Un conjunto de experimentos valida el marco teórico y la aplicación como un sistema de desarrollo de robots con una capacidad de reconocimiento de señal adaptativa y autónoma. El planteamiento teórico requiere la armonización de ideas provenientes de múltiples campos, es decir, es un trabajo realizado dentro de un área de investigación multidisciplinar, proponiendo soluciones a diferentes problemas técnicos y de planteamiento de la Robótica Evolutiva.

Organización

La primera parte de esta memoria la forma el capítulo en el que se presentan los objetivos de este trabajo a partir de los que se decide qué problema se quiere solucionar, un análisis del área de investigación y el problema implementado que cubre los objetivos.

La segunda parte hace un recorrido por la historia científica hasta el surgimiento de la Robótica Evolutiva. Posteriormente analiza dicha disciplina y las herramientas usadas, que son los componentes básicos de la mayoría de los trabajos en Robótica Evolutiva, a saber, los Algoritmos Genéticos y las Redes Neuronales. Una vez definido el entorno, se pasa a describir con detalle los problemas de la Robótica Evolutiva, y cómo se han intentado solventar.

La tercera parte describe el sistema TOPOS, desarrollado en este trabajo y que aborda dichos problemas, y expone el diseño y resultados de los experimentos que prueban la capacidad del sistema.

Por último, en la cuarta parte se evalúan los resultados generales que resuelven los objetivos, se elaboran las conclusiones y se plantea el trabajo futuro.

Como ayuda se incluye un glosario en el que se aclaran los significados de los conceptos menos habituales o con diferentes cargas semánticas para varias áreas de investigación. Además se estructura la memoria con los índices alfabético, general, de tablas y de figuras.

Parte I

Área de investigación y objetivos del trabajo

Análisis del área de investigación y objetivos del trabajo

Esta memoria documenta el trabajo realizado para desarrollar una aplicación denominada TOPOS y el marco teórico necesario para diseñarla. El objetivo principal elegido es el desarrollo de un sistema de navegación mediante evolución de redes neuronales recurrentes y dinámicas o Redes Neuronales de Pulsos (Maass, 1999), dentro de la Robótica en Entornos No Estructurados. Se puede definir como entorno no estructurado a los entornos en los que no es viable que un agente pueda disponer de un mapa de su entorno por lo complejo o lo cambiante del mismo (Arkin, 1998). La aproximación a este tipo de problemas se realiza en este trabajo a través de la disciplina llamada Robótica Evolutiva (Nolfi y Floreano, 2001), en la que se usa Estrategias Evolutivas o Algoritmos Genéticos¹ (Goldberg, 1989). Para mostrar las capacidades del sistema TOPOS y la eficacia de los individuos resultantes se diseña un conjunto de pruebas de la aplicación y se analiza el resultado de cada una de ellas.

La aplicación consiste en la simulación de un entorno en el que un agente (un robot virtual) desarrolla un comportamiento de navegación en un espacio bidimensional mediante la discriminación de señales complejas y variables en el tiempo (como es el sonido real). La discriminación de sonidos se basa en una extracción de características no supervisada y adaptativa, gracias a las Redes Neuronales y su parametrización mediante los Algoritmos Genéticos. Las señales varían por la posición del agente, que las percibe de diferente forma e intensidad según se mueve, y porque la señal cambia en el tiempo al ser una secuencia de notas o configuraciones del objeto emisor de sonido. Los puntos emisores del sonido actúan como puntos de referencia en el comportamiento de navegación.

La Robótica sigue necesitando mejoras en las capacidades de los robots cuando se trata de entornos impredecibles y no estructurados, en los que la aplicación de la Inteligencia Artificial ha sido habitual. En los últimos años

¹En este trabajo no se pretende usar las denominaciones de forma estricta, debido a que no hay unanimidad entre autores y disciplinas a la hora de nombrar métodos. De la misma forma, hay términos que implican una profunda discusión en cuanto a límites y definición como Autonomía o el ya mencionado concepto de Entorno No Estructurado, debate en el que no se entra por encontrarse fuera de los objetivos del trabajo.

los modelos conexionistas como las redes neuronales han abierto nuevos caminos en el desarrollo de controladores de robots para entornos no estructurados por sus capacidades de adaptación y de reconocimiento de patrones.

El planteamiento teórico requiere la armonización de ideas provenientes de múltiples campos, es decir, es un trabajo realizado dentro de un área de investigación multidisciplinar. A partir de ahí se desarrolla un conjunto de experimentos con el doble objetivo de mostrar la validez del marco teórico y de solucionar un problema técnicamente difícil de una manera original. En la siguiente sección se describe el área de investigación de tipo multidisciplinar, y posteriormente se define con detalle el conjunto de objetivos de este trabajo.

1.1. Área de investigación: antecedentes y estado actual de la cuestión

Este trabajo de Robótica Evolutiva consiste en la aplicación de técnicas inspiradas en la Biología y la Psicología (la Teoría de la Evolución de las Especies y el **Conexionismo**) con el objetivo de obtener sistemas no supervisados de control de robots móviles usando técnicas de selección artificial. Se denominan *no supervisados* los sistemas que no requieren un humano que controle todo o parte de la operación. A veces con este significado se usa la expresión de *Robótica Autónoma*.

La Robótica es un amplio campo en que se incluye el control de los brazos robóticos de una cadena de montaje y los robots móviles, ya sean autónomos o teleoperados (Siegwart y Nourbakhsh, 2004). La tecnología necesaria para diseñar la parte física se describe en libros como el de Craig (1989). Arkin (1998) se ocupa de la parte de control y aborda este problema de la Robótica móvil a través de la imitación de comportamientos animales, lo que se denomina *Robótica Basada en el Comportamiento*. Esta inspiración en los mecanismos que usan los seres vivos para sobrevivir se puede abordar con una multitud de diferentes técnicas y aproximaciones. Arkin (1998) describe una clasificación en un rango que abarca desde los sistemas deliberativos hasta los sistemas reactivos denominado *espectro del control robótico*. La posición en ese continuo se determina en función del peso de características, de tal forma que los deliberativos puros son simbólicos, dependientes de la representación, basados en Inteligencia Artificial, y con inteligencia de alto nivel. En el otro extremo están los totalmente reactivos, que son reflejos, libres de representaciones, basados en sistemas conexionistas, y con inteligencia de bajo nivel. En general este texto asigna los entornos estructurados y altamente predecibles a los sistemas deliberativos (o jerárquicos) y los entornos dinámicos e impredecibles (los entornos no estructurados) a los sistemas reactivos. La causa por la que los sistemas reactivos dan mejor rendimiento en entornos no estructurados es que acoplan percepción y acción al establecer una relación sintáctica (sin significados) entre entrada y salida. En este entorno tienen sentido los planteamientos realizados en el trabajo que se presenta, así como los conceptos importantes que marca Arkin (1998): **corporeidad**, **ubicación**, **emergencia**, el problema de basarse en símbolos, entornos dinámicos y escalabilidad, temas que se analizarán más adelante. También se puede indicar que este trabajo está relacionado con las equivalentes **subsimbólicas** y sintéticas de la Inteligencia Artificial, el **conexionismo**, la Vida Artificial y la Inteligencia Computacional.

Hay trabajos que se clasifican bajo el nombre de *sistemas biomiméticos*, por implementar comportamientos descritos en la literatura biológica y referirse explícitamente a la inspiración biológica de su aproximación. El trabajo de Franz y Mallot (2000), que recoge la definición anterior, considera en concreto el estudio de la navegación. Los beneficios de este tipo de trabajos son, en sus propias palabras, que proveen pruebas de modelos biológicos de comportamiento de navegación, y que se crean nuevos mecanismos de navegación para aplicaciones técnicas. Remarcan posteriormente que los comportamientos de navegación más simples se han implementado con éxito, pero no las capacidades de alto nivel.

Este trabajo parte de la idea de que un trabajo de Robótica de este tipo debe encuadrarse en un entorno multidisciplinar en el que la Biología, las **Neurociencias**, las Matemáticas, la Física y la Filosofía aporten conocimientos

y puntos de vista diferentes para encauzar el trabajo técnico. El enfoque multidisciplinar proporciona un resultado consistente, flexible y adecuado a los problemas cada vez más difíciles que se abordan. En el caso de no enfrentarse de esta manera a los problemas, el sistema dependería del programador y de su habilidad de observar el entorno y aplicar las técnicas que considere adecuadas, encerrado en una visión limitada de su disciplina. A partir de un grado de complejidad² del entorno el diseño a mano resulta inviable debido a la imposibilidad de que el programador controle todas las posibles interacciones. Ante esta situación la vía multidisciplinar amplía posibilidades de éxito, ya que aporta las técnicas evolutivas y la base conceptual para desarrollar el sistema de tal forma que las soluciones emerjan en la interacción de unidades bio-inspiradas.

Trabajar en este entorno no implica tener que perder el rumbo de la Ingeniería, en la que se sacrifica la *pureza* del marco teórico si es necesario para la obtención del resultado. En este trabajo el objetivo no es hacer un modelo exacto de un cierto ser vivo, sino usar las diferentes teorías para inspirar métodos que proporcionan soluciones, y ello implica ignorar muchas características reales de los sistemas vivos elegidos como modelo para llegar al resultado deseado. Se puede poner como analogía la creación de un juego de ordenador en el que se conducen coches de Fórmula 1. El diseño está guiado por los conceptos de *jugabilidad* (es necesario que sea posible jugar y divertirse) e *inmersión* (tiene que ser creíble hasta el punto de poder autoengañarnos), siempre bajo la restricción de la potencia de una videoconsola u ordenador doméstico. Si se sacrifica (falseando) para cumplir las anteriores premisas el modelado de la física o del comportamiento real de un bólido o de los pilotos contrincantes simulados, el juego no será un modelo adecuado del mundo de la competición, pero cumplirá sus objetivos y seguirá siendo interesante como un primer acercamiento al modelo. De hecho, es suficientemente interesante como para que sea habitual que los propios pilotos de F1 usen juegos para entrenarse en ciertos circuitos cuando no les es posible practicar realmente en ellos.

Este trabajo toma la Robótica Evolutiva como una disciplina técnica que se necesita basar en la teoría, con el fin de desarrollarla adecuadamente sobre unos sólidos fundamentos. Sin embargo, y debido a la complejidad de los problemas abordados, la teoría puede no ser capaz de prever problemas y ventajas de planteamientos. Por ello se debe usar la pura experimentación para observar el funcionamiento del planteamiento teórico, sus bondades y debilidades. de forma similar al desarrollo de prototipos industriales, o la investigación en “laboratorios” como la Fórmula 1 en los que la prueba en pista y el ajuste de los sistemas por parte del piloto o mecánicos aplicando la intuición mediante *prueba y error* es imprescindible. Como consecuencia, se construye un modelo tras elegir una base teórica adecuada y se validan las suposiciones realizadas comprobando las siguientes funcionalidades clave del sistema, en las que se persigue un avance como parte de los objetivos del trabajo.

Muchos trabajos en Robótica que abordan este tipo de problemas tienen un defecto fundamental. El programador diseña el problema de manera que ha de definir a priori los módulos sensoriales, lo que es información relevante para el agente. Ahora bien, esto plantea un problema, pues esta estrategia conlleva el que el programador necesita conocer a la perfección el conjunto de sensores e incluso imaginar qué información envían al resto del sistema de control del robot y así poder pensar cuál es la información relevante y en qué casos. En los casos en los que se usan sistemas automáticos de aprendizaje para obtener comportamientos se plantean numerosos problemas por la variabilidad del entorno, el ruido de la señal y la dificultad de analizar el comportamiento de sistemas que resultan *cajas negras*. Y son precisamente estas dificultades las se pretenden solucionar con el presente enfoque ya que, en lugar de predefinir todos estos valores, el planteamiento evolutivo implica una estrategia que permite *hacer emerger*, de manera similar a la que ocurre en los sistemas biológicos, la estructura perceptiva que extrae la información relevante. El trabajo que se presenta en esta memoria tiene además como objetivo eliminar los problemas

²El término “complejidad” tiene varias acepciones ya que puede significar sencillo u homogéneo, fácil de describir, o puede tener relación con los Sistemas Complejos, en los que la *complejidad* se entiende de la forma definida en el glosario. En esta memoria se tiende a usar el primer significado, pero es necesario tener en cuenta que detrás de cualquier sistema conexionista puede haber dinámicas que son complejas según esta acepción.

señalados por Brooks (1990, 1991a) (el problema de basarse en símbolos y la falta de *corporeidad* y *ubicación*) y mostrar las capacidades de los componentes elegidos ante los problemas de percepción del entorno como son la variabilidad del entorno y el ruido.

Cuando la Robótica Evolutiva se aplica en problemas que resuelven los seres vivos, los enfoques de la Vida Artificial pueden ser de gran ayuda, puesto que simula los comportamientos observados en la Naturaleza y desarrolla modelos que expliquen el funcionamiento de los sistemas vivos (Langton, 1989). Por esa razón, este trabajo aprovecha los planteamientos, conocimientos y conclusiones de la Vida Artificial junto con las técnicas, modelos y simulaciones que son habituales en esta disciplina para construir sistemas que realizan tareas propias de los seres vivos, en particular la Robótica Evolutiva.

La Vida Artificial intenta explicar la inteligencia como un proceso emergente y *autoorganizado*, al contrario que la Inteligencia Artificial, que trata de reproducir las capacidades cognitivas a partir de un diseño explícito. Un aspecto importante de la Vida Artificial es que, al contrario que lo habitual en la Inteligencia Artificial, el esquema es distribuido y emergente. En otras palabras, los comportamientos *emergen* o aparecen como consecuencia de que se plantean sistemas especificados a muy bajo nivel en los que la interacción de sus partes determina el comportamiento global. En la Inteligencia Artificial el experto crea un sistema que contiene todo su conocimiento, desarrollado de forma estructurada, en gran parte con diseño descendente. Cada parte del sistema tiene una función asignada, y se diseña especialmente para producir cierto comportamiento. En cambio, en la Vida Artificial el diseñador sólo establece una serie de reglas locales simples, que se seleccionan en función de su capacidad para dar lugar a las estructuras y comportamientos esperados para cada subsistema a partir de la interacción de las partes. En este tipo de sistemas la estructura inicial es muy indiferenciada y los procesos funcionales emergen como resultado de dinámicas altamente distribuidas y masivamente paralelas.

Esta estrategia ha mostrado su eficacia aportando gran cantidad de información durante los últimos veinte años. No obstante, hay todavía una gran distancia entre este tipo de trabajos y muchos de los modelos y enfoques más estándares en *Neurociencias*, que se basan en metodologías analíticas y *reduccionista*, consistentes en la investigación de partes funcionales y su estructuración en mecanismos (Bechtel, 2007).

En este trabajo la fidelidad a la realidad en toda su complejidad es mucho más modesta, pues el objetivo que se pretende no es reproducir ni explicar los mecanismos neuronales que efectivamente están involucrados en tales tareas en el mundo animal. El objetivo es principalmente técnico y por ello busca sólo la inspiración biológica en el sentido práctico de solución de un problema de ingeniería, no de explicación de un proceso neuronal del mundo animal. El trabajo de conjunción de sistemas que ya están analizados por separado proporciona avances en varios campos, pero sobre todo permite afirmar que es posible usar este método para desarrollar robots capaces de tareas complejas en entornos no estructurados sin intervención humana.

1.2. Objetivos del trabajo

En esta sección se pasan a definir los objetivos del trabajo que se documenta en esta memoria. Los objetivos justifican el desarrollo del marco teórico, que interpreta la información bibliográfica (capítulos 2 y 3), y marcan el diseño del sistema que permite producir el robot descrito como objetivo principal (capítulo 4).

1.2.1. Obtención de un robot con un comportamiento de navegación en entornos no estructurados

Este trabajo tiene, por tanto, como objetivo principal el de diseñar un robot capaz de diferenciar señales variables en el tiempo, y usarlas en el comportamiento de navegación como puntos de referencia en un entorno sin mapas ni otros sistemas de localización. En el diseño no hay indicaciones sobre cómo y en qué se deben basar los robots para diferenciar las señales y cómo se deben desplazar para ello. La mano del investigador no introduce comportamientos, sino sólo la estructura que cree suficiente (aunque quizás con partes no necesarias) para que emerja y se desarrolle un comportamiento que no está explícito en el diseño del control del robot.

Como ya se ha indicado al principio de este capítulo, este trabajo se encuadra en el área de la Robótica en Entornos No Estructurados, en la que el robot es un agente que debe desarrollar capacidades perceptomotrices para poder *navegar* por su entorno en función de lo percibido, ya que es inviable, complejo o imposible disponer de un mapa. Para este planteamiento la inspiración biológica tiene ventajas evidentes. De la misma forma que en la Naturaleza, el robot bioinspirado exhibe comportamientos supuestamente más complejos que lo que se pudiera pensar para sistemas de control simples.

Bajo el término *navegación* este trabajo se refiere al movimiento dirigido de un agente. Este movimiento es generado analizando aquella información sensorial que el agente necesita para realizar sus funciones vitales. El agente extrae las características, la información o *señal* de los *parámetros físicos* (las mediciones que los sensores realizan en el entorno). Para ello es necesario que tenga la capacidad de obtener puntos de referencia espaciales (*landmarks*) a partir del conjunto de datos o parámetros físicos que le llegan desde cada punto, por uno o varios sentidos. Los puntos de referencia son el resultado de aislar un conjunto de características de los parámetros físicos. Esas características se encuentran situadas en todas las dimensiones de los parámetros físicos, tanto en el espacio (configuraciones visuales o frecuencias auditivas) como en el tiempo (los valores físicos varían en un entorno cambiante).

En este contexto, el problema de la percepción de señales se puede tratar como un problema de *reconocimiento de patrones* en el que se debe elegir una técnica de procesamiento de la señal y un tipo de señal adecuado. Hay innumerables métodos de reconocimiento de patrones, pero lo habitual es que se basen en el almacenamiento de la señal y su procesamiento separado del sistema sensorial (lo que en Informática se suele llamar "*off-line*"). Dicho método es muy dependiente del programador y del contexto. Si se usan redes neuronales se puede obtener un sistema de extracción de características adaptativo y autónomo, apropiado para entornos no estructurados.

El diseño de redes neuronales y otros sistemas con gran cantidad de parámetros que definen su funcionalidad resulta inviable según crece la dificultad del problema y con ello el número de valores que determinan el sistema. Como consecuencia, el diseño *a mano* se abandona y se buscan mecanismos automáticos como los denominados Estrategias Evolutivas y Algoritmos Genéticos, que permiten solucionar un problema evaluando posibles soluciones y combinando las mejores para crear una nueva generación con la que se repite el proceso de selección y mezcla. Este planteamiento es la base de la Robótica Evolutiva, y se puede interpretar como un sistema de búsqueda de soluciones, de optimización, o como un sistema que intenta utilizar las mismas técnicas que la Naturaleza ante problemas semejantes.

En una primera aproximación el programador elige, adapta o diseña un modelo de red neuronal y de otros módulos que componen el agente o robot. Las estrategias evolutivas se aplican a los parámetros de cada elemento. Por ejemplo se varía el umbral de disparo de una cierta neurona o la frecuencia a la que es más sensible un sensor. En trabajos futuros se verá si es viable evolucionar el tipo de módulos (como si se tratase de un proceso de diferenciación celular) y la cantidad de parámetros.

Para el enfoque conjunto de reconocimiento de patrones y navegación planteado en este trabajo se ha elegido una estrategia diferente, utilizando Redes Neuronales de Pulsos (Maass, 1997, 1999). Las Redes Neuronales de Pulsos tienen las características de ser recurrentes y dinámicas, es decir, puede haber ciclos en su estructura y son matemáticamente equivalentes a los Sistemas Dinámicos, como se señala en el apartado 3.4. La razón de elegir este tipo de redes es que con ellas es posible reconocer patrones temporales de forma paralela a la adquisición de datos y a la parte motora, sin producir un aumento de complejidad en el diseño del sistema de control de los robots.

Este modelo de red neuronal, de mayor inspiración biológica que las *sigmoideas*³, nos permite el procesamiento temporal de la señal para reconocer patrones complejos y diferentes informaciones en la señal suministrada por los sensores. Este tipo de redes neuronales también facilita describir el agente como un Sistema Dinámico acoplado al entorno en el que está ubicado porque son equivalentes a las *Continuous Time Recurrent Neural Networks* (CTRNN, ver sección 3.4.2), y éstas se pueden describir como un Sistema Dinámico (ver el apartado 3.4).

Las capacidades de las redes neuronales (robustez, generalización) se muestran más claramente en señales reales, no generadas por la simulación, y en señales a las que se añade ruido.

El reconocimiento de señal es más interesante cuando ésta varía en el tiempo y hay que combinar características diferenciables en un instante de tiempo (frecuencia e intensidad) con estímulos anteriores. Por esto precisamente se elige un modelo de red neuronal, denominado *de pulsos*, que facilita la tarea de procesamiento temporal de la señal debido a la dinámica de sus neuronas.

Cuando la señal varía en el tiempo independientemente de la actividad motora del robot el problema de generar comportamiento se vuelve más difícil, porque es necesaria una coordinación del comportamiento con el entorno y porque no se dispone de una determinada parte de la información en cualquier momento.

1.2.2. Impulso de los objetivos técnicos de la Robótica Evolutiva

En la Robótica Evolutiva han sido objetivos principales el estudio de la cognición, la filosofía de la mente y la biología teórica (Harvey et al., 2005). En este trabajo se impulsa la Robótica Evolutiva como disciplina técnica para incluir como tema de trabajo la búsqueda de una correcta selección de las diferentes partes y su ajuste con el fin de obtener robots que realicen correctamente una tarea en el mundo real. Esto no quiere decir que se den por cerrados los objetivos puramente científicos ya citados, sino simplemente que en esta tesis se toma como principal la vía de trabajo de tipo técnico, que tiene un fin por sí misma, y además proporciona nuevos datos para el desarrollo de las otras perspectivas (ver la sección 3.2).

Si se quisiera obtener conocimiento científico como objetivo principal del trabajo (que es lo que se hace en la Vida Artificial tomada de forma estricta) se debería buscar una cierta característica y *aislarla* mediante la simplificación, para que las interacciones fueran mínimas y por lo tanto fuera analizable. Se modelaría lo estrictamente necesario para ser fiel al funcionamiento de la característica objeto de estudio. Sin embargo, en este caso el objetivo es comprobar que se han escogido las técnicas y los análisis científicos y filosóficos adecuados con el fin de *construir* un robot capaz de llevar a cabo una determinada tarea. Posteriormente se debe analizar en lo posible los resultados y las posibilidades y dificultades que ha mostrado el método de trabajo, con el fin de mejorarlo.

³El valor de activación de una neurona sigmoidea se puede interpretar como una medida de frecuencia media de disparo de la neurona en un instante determinado, mientras que en las redes neuronales de pulsos se representa cada uno de los pulsos.

1.3. Problema implementado en la aplicación Topos

El principal de los objetivos es desarrollar un robot autónomo que sea capaz de realizar una tarea de navegación a partir del reconocimiento de patrones en señales analógicas (más de dos estados), compuestas (multidimensionales) y variables en el tiempo. Al tener en cuenta los demás objetivos mientras se construye el sistema se cubre la totalidad de objetivos del trabajo.

Se ha elegido el sonido como señal que debe percibir el robot como punto de referencia. El sonido es ejemplo de señal unidimensional variable en el tiempo con una dinámica lo más general posible, e independiente de la acción del robot. La elección del sonido en lugar de la vista se debe a que la vista es un sentido más complejo porque puede interpretarse como la conjunción espacial de un gran número de señales de este tipo, y sería necesaria demasiada capacidad computacional. Por otra parte, los gradientes de señal continua como olores y otros tipos de señales químicas son demasiado sencillos pues no varían en el tiempo de forma independiente del movimiento del robot. Esto es, si el agente está quieto la señal es constante. El sonido sería equivalente a la luz si planteáramos el experimento con dos fuentes de luz parpadeantes, cada una con diferente intensidad y color en cada momento. Los sensores del robot podrían ser sensibles a distintas frecuencias del espectro visible, a cada color, y en un rango de intensidades. El ruido en la señal y la aleatoriedad en la activación de los sensores facilitan la robustez del sistema y la flexibilidad ante fallos en los motores, por ejemplo.

Se crea un entorno de simulación para realizar las pruebas de los robots. En el entorno o *arena* (superficie de funcionamiento) se sitúan dos sonidos separados por una cierta distancia. Para obtener el agente que realice correctamente la tarea de navegación se usan Algoritmos Genéticos. Un agente se reproduce (esto es, su estructura pasa a la siguiente generación si da buenos resultados en un cierto número de pruebas en un esquema tipo caja de Skinner (ver subsección 2.9.3), en el que se lleva a cabo un experimento premio-castigo. El agente (o robot) debe acercarse a un sonido determinado al principio de la ejecución del Algoritmo Genético y alejarse del otro. Como ya se ha indicado, en la simulación se hacen varias pruebas por cada robot, en las que un robot empieza equidistante y enfocado a dos fuentes de sonido real y debe acercarse a una de ellas y alejarse de la otra. Los sonidos se posicionan al azar a cada lado. La elección por parte del robot de uno de los dos sonidos está marcada por la presión selectiva de la evolución a través de la función de adecuación o *fitness*, que marca cuál es al que deben acercarse, cuál es el *correcto*. Por ello se podría decir que el comportamiento de los individuos es *instintivo*, al ser resultado de la evolución y *ontogenéticamente* invariable. El Algoritmo Genético selecciona a los individuos que se acerquen más al sonido correcto, y elimina a los que se acerquen al otro o a ninguno. Para ello cada agente debe *percibir* los sonidos y diferenciarlos con el fin de usarlos como puntos de referencia en su movimiento. En la percepción actúa la morfología de los sensores y la red neuronal que activa los motores.

En un Algoritmo Genético se clasifican las posibles soluciones al problema según la puntuación que le asigna la función de adecuación (*fitness*). En este caso se debe valorar si el agente realiza *bien o mal* el comportamiento deseado. Este tipo de problema, en el que el agente debe acercarse al lugar adecuado, elimina las dificultades de tener que evaluar el comportamiento y de creación de la función de adecuación. Esto es debido a que, en vez de usar criterios puramente subjetivos sobre el comportamiento del agente, simplemente se calcula la distancia al objetivo más una constante en caso de llegar a una distancia mínima. Esta constante que se suma al valor de adecuación es un premio que permite reforzar la posición del individuo dentro de la presión selectiva del Algoritmo Genético.

El problema planteado permite *desdoblarse* la función de adecuación: la primera es la *fitness* propiamente dicha, que permite la clasificación de las soluciones como se indica en el párrafo anterior. La otra es una medida absoluta sobre la capacidad de los robots en hacer la tarea. El diseño “*caja de Skinner*” abre la posibilidad de definir una medida que marque el comportamiento como correcto, incorrecto y fallido. En otras palabras, se contabiliza si el

robot acierta, falla o no consigue dar una respuesta adecuada y llegar a un sonido. Con esta medida absoluta se sabe no sólo si es el mejor comportamiento de la población (como ocurre en el trabajo de Floreano y Mattiussi (2001), por ejemplo) sino si hace el trabajo a la perfección con un 100 % de efectividad o elige la fuente de sonido de forma aleatoria dando un 50 %.

El sonido es un buen ejemplo de señal analógica multidimensional en lo relativo a frecuencias y variable en el tiempo. Es equivalente a un conjunto de señales unidimensionales completamente sincronizadas, como de varios sensores que detectan diferentes características del mismo objeto. Es una señal real (grabada del mundo real y no generada en la simulación), que suministra gran cantidad de información que maneja el sistema perceptivo del robot para producir un comportamiento que podría separarse en dos capas. La capa básica es reactiva, una *taxia*, implementada en la propia red neuronal. Este comportamiento se ve modificado por la propia dinámica de la red neuronal, en función de la *sensación* de repulsión o atracción que le produce cada uno de los sonidos. El agente desarrollará un comportamiento innato de acercamiento, obtenido *filogenéticamente*, que se puede definir como una atracción. Análogamente, el alejarse de la fuente de sonido que baja el valor de adecuación puede denominarse un comportamiento de repulsión.

El sonido varía en el tiempo aunque se mantenga quieto el robot, lo que le añade el problema de coordinación al comportamiento. Otra dificultad añadida es el ruido que se le introduce al sensor en la conversión del sonido en activación sensorial.

Dentro de la capacidad perceptiva se encuentra la evolución de los sensores y su procesamiento previo de la señal (oído externo). Las Redes Neuronales de Pulsos son la otra fase de la percepción. Estas redes neuronales permiten el procesamiento temporal de la señal al filtrar y componer las señales recibidas de los sensores y detectar patrones complejos. De esta forma reconocen diferentes informaciones en la señal suministrada por los sensores y pueden generar las activaciones adecuadas a los motores. Al ser estas redes matemáticamente equivalentes a un Sistema Dinámico genérico, se puede describir el agente como un Sistema Dinámico acoplado al entorno en el que está ubicado. Se pretende comprobar la capacidad de las redes neuronales de pulsos para facilitar la tarea de reconocimiento y discriminación de señales con estructura temporal como el sonido. El individuo necesita una capacidad perceptiva adecuada y que le permita distinguir estímulos y producir reacciones. La señal puede ser un sonido real, del tipo del que podemos obtener con un micrófono o de un disco de música u otro medio audiovisual. Es importante la selección y transformación de parte del estímulo como una fase del proceso de percepción, y ésta es la tarea que realizan los sensores. El modelo implica pues una evolución o *morfogénesis* de los sensores, como se explicará a continuación.

El número de dimensiones en el espacio de estados en el que se busca alguna característica reconocible crece con las posibilidades de variación de la señal, por lo que encontrar un patrón es mucho más difícil. Por eso, el sensor debe disminuir la cantidad de información entrante seleccionando las bandas de frecuencia que sea capaz de usar. Un estímulo puede tener una variabilidad temporal que no depende de la posición y movimiento del robot, por lo que éste debe detectar las características adecuadas de la señal para reconocerla sin usar su propio movimiento.

En el desarrollo de sensores para navegación uno de los problemas que nos podemos encontrar es que hay datos absolutos y datos relativos, es decir, señal de la fuente y señal a cierta distancia. La señal se atenúa en función de la distancia del foco emisor, debido a que se irradia una determinada cantidad de potencia por estereorradiación (unidad angular tridimensional). Alternativamente, se define la potencia de un emisor en la unidad de " W/m^2 a un metro" de distancia del mismo. Por tanto, el sensor debería procesar la información en un muy amplio rango de intensidades, bien acomodándose a cada intensidad, o con diferentes baterías de sensores para cada intensidad.

Se hace solamente trabajo en simulación, ya que éste es un estudio para comprobar la viabilidad del sistema, la validación del marco teórico, y detectar los posibles problemas y cambios, entre ellos si el sistema es escalable.

Este trabajo es de carácter exploratorio, de la misma forma que lo hacen Floreano y Mattiussi (2001). Actualmente, la Robótica Evolutiva todavía no es una disciplina con directrices estables y resultados directos. En este punto de la investigación no es realista pretender obtener robots cuyas capacidades en el mundo real justifiquen el esfuerzo añadido de conseguirlos fuera de una simulación. Además, el trabajo que ocasionaría ese paso se puede invertir en un futuro en estudiar la forma de ampliar la escalabilidad a partir del desarrollo de mecanismos *morfogenéticos*. Esta generación dinámica de la forma del robot (incluida su parte de control) permitirá una mejor adaptación al entorno con menos información genética.

El esquema de este experimento es lo más reducido posible en cuanto al problema de navegación a partir de puntos de referencia. Se plantea conseguir que el agente diferencie entre dos señales que vienen de dos puntos en el espacio, que cambian en el tiempo, y que cambian según el robot se mueve, debido a que el robot está *ubicado* en su entorno. El problema de usar dos puntos de referencia diferenciando sonidos es el más simple dentro del problema de navegación definido. Se elige un problema simple por dos razones: la primera es que el sistema dé resultados, y que los dé en un tiempo adecuado; la segunda es conseguir un diseño realizable, y que el análisis de los resultados sea posible.

No existe aprendizaje por parte de los robots y al comportamiento que desarrollan se le podría denominar *innato*. En otras palabras, la adaptación en este esquema es puramente *filogenética*. El comportamiento apropiado permite la supervivencia del individuo y la herencia de ese comportamiento a su descendencia. De la misma forma, el comportamiento inadecuado no se hereda al no sobrevivir el agente. El robot no cambia durante sus interacciones en ningún valor de los que define la información genética. No hay aprendizaje *hebbiano* (Hebb, 1949) o cualquier otro tipo de adaptación *ontogenética* mediante modificaciones de la estructura del robot, que permanece inalterada tal como está codificada en el genoma, la descripción numérica del robot. Se consideran estructurales los pesos de las conexiones entre neuronas y otros elementos. La recombinación y la mutación del algoritmo genético son las herramientas que crean nuevas redes neuronales y nuevos individuos, que pueden dar mejor resultado o no.

La escalabilidad (ver la sección 3.10.2) y como consecuencia la posibilidad de abordar problemas cada vez más complicados es el gran muro de la Robótica, como afirma Arkin (1998). El trabajo puede mostrar la capacidad del sistema de ser usado a gran escala, con problemas de mayor tamaño, o la dificultad que habría en su caso. Es necesario plantear un problema complicado pero sin llegar a ser imposible, que demuestre las capacidades de los módulos elegidos, y muestre que las suposiciones realizadas en la fase de diseño son adecuadas.

Parte II

Estado del Arte: Informática, Inteligencia Artificial y Robótica Evolutiva

De la Lógica a la Robótica Evolutiva

En este capítulo se hace una interpretación histórica de las disciplinas relacionadas con esta tesis, principalmente la Informática, la Inteligencia Artificial y la Robótica. No se pretende en absoluto hacer una descripción del qué, cuándo y cómo de cada una de las ramas y hechos ocurridos durante la ya larga historia de la Inteligencia Artificial, sino plantear un discurso que los interprete para entender por qué y a partir de qué llegamos a la Robótica Evolutiva (y por ello no se da bibliografía de todo lo que se indica, sino sólo de lo más cercano a este trabajo). Por supuesto, para un recorrido histórico objetivo (o menos subjetivo) se puede consultar una de las “biblias” de la Inteligencia Artificial, como pueden ser la escrita por Barr et al. (1986) y la de Russell y Norvig (1994).

2.1. La Inteligencia Artificial y su relación con la Informática

La informática es, etimológicamente, el procesado automático de la información. Los mismos que introdujeron el cero en la cultura europea¹ le pusieron nombre a la descripción de un proceso bien definido que trata información: *algoritmo*². Ha habido muchos intentos de crear máquinas capaces de procesar información, pero la tecnología no lo permitió (y quizás la economía) de manera satisfactoria en la relación coste/beneficio hasta la Segunda Guerra Mundial, en la que los complicados cálculos de balística y la criptografía promovieron la creación de los primeros ordenadores.

El surgimiento de la informática es consecuencia de la necesidad del ser humano de calcular, pero cuando se tuvo la máquina surgió la curiosidad por automatizar el pensamiento. La posibilidad de crear inteligencia artificial

¹Los árabes trajeron el cero a Europa en la Edad Media desde la India, aunque el primer indicio del cero parece encontrarse en jeroglíficos mayas

²El matemático, astrónomo y geógrafo musulmán Abu Abdallah Muhammad ibn Musa al-Jwarizmi, conocido generalmente como al-Jwarizmi, es el origen de las palabras álgebra, guarismo y algoritmo, por su nombre y por el título de su obra principal, *Hisab al yabr ua al muqabala*. Se le considera padre del álgebra e introductor del sistema de numeración decimal.

fue una preocupación permanente de los creadores de la informática, como por ejemplo Alan Turing. De hecho, el ser humano ha intentado siempre representar sus pensamientos primero con la palabra en otras mentes, posteriormente con el dibujo y la escritura. Mucho después, según fue desarrollando las matemáticas y la lógica, buscó sistemas de representación que realimentaron el pensamiento, por ejemplo a producir el concepto de *cero* para cuadrar la representación (si vendemos por el mismo precio que compramos, el beneficio es cero).

La evolución que ha tenido la informática era impensable en aquellos momentos, que se pensaba circunscrita a ejércitos y empresas de gran tamaño. Se hizo famosa la frase³ que expresaba la necesidad mundial de como mucho unos cuantos ordenadores. Sin embargo, quedaba por sopesar el interés humano de crear a su imagen y semejanza, ya satisfecha con la imagen de sí mismo con el dibujo y pintura, con la fotografía y el cine. Otra vez la tecnología puso límites al desarrollo y sólo se encaró el problema de crear inteligencia, factible debido a la existencia de los ordenadores. El problema de construir clones artificiales de los humanos se quedaba en sencillos autómatas.

La definición oficial de la Inteligencia Artificial dada por McCarthy es “la ciencia y la ingeniería de construir máquinas inteligentes”. Hay muchas definiciones de Inteligencia Artificial porque resulta difícil definir la propia Inteligencia, y por ello incluye la propia idea de inteligencia en la definición. Una definición alternativa de la Inteligencia Artificial es el conjunto de sistemas que buscan solucionar los problemas que carecen de solución algorítmica directa o analítica, de la misma forma que hay ramas de las matemáticas con mecanismos no analíticos como el cálculo de Newton. En estas matemáticas las soluciones son una aproximación, ya que no existe un método *perfecto*.

2.2. Cerebros y máquinas

La primera aproximación a un problema como crear inteligencia es replicar la base física relacionada con esa característica, de la misma forma que la primera forma de intentar volar fue usar alas fabricadas con plumas de ave. En los trabajos de Ramón y Cajal se describe la naturaleza discontinua del cerebro, formado por células independientes conectadas en las sinapsis.

La forma directa y más sencilla de representar el funcionamiento de las neuronas (teniendo en cuenta las restricciones de la ínfima capacidad computacional de entonces) fue asignar un estado de activación binario a cada neurona, y una función lógica binaria de cálculo del siguiente estado a partir de los estados de ciertas neuronas de la red. La actualización de este modelo desarrollado por McCulloch y Pitts (1943) es por tanto síncrona.

Con esta estructura se acerca bastante esa réplica de cerebro al ordenador, por el funcionamiento binario y la aplicación del álgebra booleana en la que el propio Boole habla de leyes del pensamiento (Boole, 1854). Es curioso observar que la analogía del cerebro pasó de ser la red telefónica al ordenador tras la invención de las computadoras, que incluso éstas recibieron el nombre alternativo de *cerebro electrónico*.

2.3. El surgimiento de la Inteligencia Artificial: la conferencia de Dartmouth. Turing y Searle

Los primeros pasos de la Inteligencia Artificial los dieron McCulloch y Pitts (1943), Hebb (1949), Shannon y Weaver (1949) y Turing (1950). Éste escribe un artículo (Turing, 1950) en el que define la famosa *Prueba de Turing* (o test de Turing). La idea de esta prueba es simple: consideraremos inteligente a un ordenador cuando sea

³Cohen (1998) dice: *Howard Aiken is reputed to have said that only a small number of computers would be needed for the needs of the whole world. But he seems to have been referring to proposed computers for the Bureau of the Census or the Bureau of Standards.*

imposible de distinguir de un ser humano, comunicándonos sólo a través de pantalla y teclado con esa persona u ordenador. Ésta es una prueba subjetiva, debido a que una persona puede sugestionarse para creer que lo que lee es producto de una mente humana y no de un programa de ordenador, como ocurre con el programa Eliza (Weizenbaum, 1966). Treinta años después Searle (1980) toma la parte pesimista de este dúo que intenta definir la inteligencia a partir del ser humano, y construye el argumento de la *habitación china*. Este ejemplo sacude los cimientos de la Inteligencia Artificial Fuerte al plantear que una máquina pensante es distinta a una máquina que parece que piensa. La parábola de la *habitación china* plantea se podría decir que una persona sabe chino simplemente si puede responder⁴ cualquier pregunta en chino basándose en un conjunto detallado de reglas que tiene en un libro. Sin embargo, no es capaz de entender la conversación aunque pueda a ojos externos establecer un diálogo coherente en chino.

La disciplina de la Inteligencia Artificial se funda “oficialmente” en el año 1956 en el Dartmouth College, en una conferencia de verano organizada por John McCarthy, Marvin Minsky, Nathan Rochester y Claude Shannon (Russell y Norvig, 1994). En la fundación de esta disciplina, la Inteligencia Artificial engloba con sus aspiraciones los trabajos anteriormente publicados por una parte en el área de la Cibernética (Wiener, 1948), y por otra parte la vía de las Redes Neuronales, el **Conexionismo** y lo que actualmente se llama **Neurociencia Computacional**. En este periodo inicial de la Inteligencia Artificial la visión era optimista y entusiasta, y se esperaban grandes logros.

Objetivos de la conferencia

En el documento⁵ que describe la propuesta para el proyecto de investigación llevado a cabo ese verano de 1956 se indican el objetivo y los puntos de trabajo iniciales:

“The study is to proceed on the basis of the conjecture that every aspect of learning or any other feature of intelligence can in principle be so precisely described that a machine can be made to simulate it. An attempt will be made to find how to make machines use language, form abstractions and concepts, solve kinds of problems now reserved for humans, and improve themselves. We think that a significant advance can be made in one or more of these problems if a carefully selected group of scientists work on it together for a summer.”

- Automatic Computers
- How Can a Computer be Programmed to Use a Language
- Neuron Nets
- Theory of the Size of a Calculation
- Self-Improvement
- Abstractions
- Randomness and Creativity

Como puntos muy importantes estaban el lenguaje y el pensamiento, por lo que además de los matemáticos, físicos e informáticos, era necesaria la colaboración de lingüistas y psicólogos. Por tanto, es interesante remarcar la multidisciplinaridad que se consideraba como necesaria al plantear esta nueva disciplina.

⁴Se define en este caso la acción de responder como el acto de enviar una secuencia de símbolos relacionada con la secuencia recibida

⁵ <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>

2.4. La época dorada de la Inteligencia Artificial: pensamiento abstracto y jugadas de ajedrez

Hasta finales de los sesenta la Inteligencia Artificial avanzó rápidamente y prometió máquinas inteligentes, traductores automáticos, jugadores de ajedrez imbatibles... No era difícil hacer grandes avances en heurística, búsqueda, deducción automática y otros tipos de operaciones similares.

John McCarthy desarrolló el lenguaje de programación LISP en 1958 como primer lenguaje de programación orientado al trabajo en Inteligencia Artificial.

2.4.1. Newell y Simon: la hipótesis del sistema de símbolos. El funcionalismo

La Inteligencia Artificial Clásica se funda en la hipótesis del sistema de símbolos. En este planteamiento los sensores suministran símbolos, por lo que el sistema de razonamiento se puede abstraer de la parte *sensomotora*. El sistema funcionará correctamente mientras la información codificada en esos símbolos sea coherente, independientemente de su significado. Sólo el observador le da un significado completo al sistema al añadir su propia experiencia.

Newell y Simon (1963) formularon esta hipótesis como consecuencia de su trabajo en el “Solucionador General de Problemas”, más conocido en inglés: *General Problem Solver (GPS)*. Afirman en este trabajo que un sistema de símbolos físicos tiene los medios necesarios y suficientes de acción inteligente y general⁶. Es decir, cualquier sistema inteligente debe operar con símbolos que combina en estructuras que modifica para producir otras. Para ver la falta de límites que tenía la Inteligencia Artificial en aquellos momentos sólo hace falta observar la definición del GPS: *máquina solucionadora universal de problemas*, desde teoremas matemáticos al ajedrez.

El Funcionalismo es una teoría sobre el funcionamiento de la mente, que afirma que los procesos mentales son independientes de la materia que los sustenta. Por ello serían fácilmente trasladables a un ordenador. Evidentemente, está íntimamente relacionada con la hipótesis del sistema de símbolos. Su crítica más conocida es la basada en el argumento de *la habitación china* de Searle (1980).

2.4.2. Sistemas Expertos

Los Sistemas Expertos también se pueden denominar Sistemas Basados en Conocimiento. De su nombre podemos obtener su objetivo y estructura, que es gestionar como una base de datos el conocimiento de un humano experto en una determinada área del saber, y manejar esa información con un motor al que se le hacen preguntas y obtiene una respuesta. Se pueden formalizar con gramáticas, ya que su estructura es un conjunto de reglas. Como lenguaje de programación de tipo lógica tenemos el Prolog, la estructuración de la información en marcos (*frames*), y como ejemplo general el MYCIN, como médico “volcado” en un ordenador.

2.4.3. Cierre de la vía de las Redes Neuronales

Con el libro de Minsky y Papert (1969) se cerró la línea conexionista justificando que los perceptrones no eran capaces de solucionar el problema del XOR, es decir, determinar si las entradas binarias son iguales o diferentes. Para entender esto se deben tomar las redes neuronales como sistemas clasificadores. En un sistema continuo este problema se traduce a la imposibilidad de separar en el plano con una recta dos conjuntos de puntos. Con un

⁶“A physical symbol system has the necessary and sufficient means of general intelligent action”

ejemplo sencillo se puede decir que en una de las aulas de la universidad es imposible trazar una línea que separe o clasifique según una cierta característica, como por ejemplo personas zurdas y diestras, o que separe altas y bajas (suponiendo un umbral, por supuesto). Además supusieron equivocadamente que una red formada por tres o más capas de perceptrones tampoco podría solucionar el mismo problema, cuando con el ejemplo anterior se ve intuitivamente que se pueden combinar rectas para formar varias áreas con forma de V.

Por muchos trabajos que modelaran complejos comportamientos de Redes Neuronales, los fondos para investigación en el **Conexionismo** cayeron drásticamente. Hasta finales de los ochenta no renació el interés por las redes neuronales con el algoritmo de retropropagación (más conocido por sus siglas en inglés BP, *backpropagation*).

2.5. Crisis y resurgimiento de la Inteligencia Artificial

Durante la época dorada de la Inteligencia Artificial cierto tipo de problemas continuaban resistiéndose. En concreto, los traductores automáticos no llegaron a ser más que un prototipo, y los programas de juego no vencen a los especialistas. Sería mucho más adelante cuando la potencia de cálculo sobrepasa a los humanos en cantidad más que por calidad en *visión de jugada*. El *General Problem Solver* se quedó, como muchos otros sistemas, en prototipos incapaces de crecer. El impulso de la Inteligencia Artificial por resolver todo tipo de problemas se fue desvaneciendo a finales de los sesenta y se redujo a los campos en los que se obtenían resultados satisfactorios.

La desaparición del área de las Redes Neuronales con el libro de Minsky y Papert (1969) y la falta de resultados en el área simbólica deja la Inteligencia Artificial en una grave falta de resultados. En esta delicada situación los investigadores en Inteligencia Artificial limitan sus objetivos a sistemas factibles, dentro de los caminos que han dado fruto, principalmente Sistemas Expertos. Se pueden destacar Dendral (1969), que determina la fórmula química a partir del espectro de masas, y MYCIN (1976), que diagnostica enfermedades bacterianas y determina el tratamiento. En 1975 aparece el PROLOG, lenguaje declarativo para hacer programación lógica.

A partir de los ochenta la Inteligencia Artificial es aceptada como técnica útil y fiable en el entorno industrial, y muchas compañías desarrollan sistemas con este tipo de técnicas. Las ramas actuales en la Inteligencia Artificial que se pueden destacar son la demostración automática de problemas, la aplicación de la Teoría de Juegos, el procesamiento del Lenguaje Natural, los Sistemas Expertos, la Programación Automática y la Robótica.

2.6. El Conexionismo

Mientras los sistemas expertos sufrían problemas de crecimiento, reaparecen las viejas ideas de crear un modelo del cerebro y de estudiar las propiedades de tales redes, sobre todo a partir del grupo de trabajo PDP (Rumelhart et al., 1986, PDP Research Group), que le da un segundo nombre al **Conexionismo**: *Parallel Distributed Processing*. La característica más importante, y la que le da nombre, es la capacidad de procesar la información repartiéndola por diferentes caminos de la red, de forma paralela y distribuida. También podemos pensar en la capacidad de procesamiento **subsimbólico** de la información, al no necesitar transformar a símbolos la entrada al sistema. Un híbrido entre esta visión y la Inteligencia Artificial clásica es la lógica difusa (Zadeh, 1965, 1968; Klir y Yuan, 1995), en la que los símbolos están parametrizados, de la misma forma que decimos que algo tiene poco peso o mucho, o algo es relativamente cierto.

Las múltiples posibilidades que ofrece este planteamiento produjeron la aparición de sistemas de clasificación, que se encuadran en este esquema pero que están muy lejanos de la inspiración biológica. Las redes neuronales más tradicionales también se han mantenido en cierta forma lejos de lo que hubiera sido modelar fielmente la

dinámica de una neurona natural. En parte ha sido así por no ser necesario para obtener el comportamiento que se le pedía a la red, por lo menos en la visión técnica. Por otra parte no se modelaba de manera más biológicamente inspirada por no conocer qué dinámica de la neurona es necesario representar en el modelo y cuál no tiene reflejo directo en el funcionamiento de la célula como neurona. Puede ser difícil determinar qué se puede abstraer, ya que evidentemente resulta imposible en la práctica simular el estado de cada molécula de una célula.

La potencia computacional permite un mejor estudio en la actualidad del paralelismo masivo de los sistemas conexionistas. Se establecen múltiples ramas que descansan en la Probabilidad (Redes Bayesianas), en las **Neurociencias** (Redes Neuronales de Pulsos), en la Topología (*Self-Organizing Maps* de Kohonen (1982, 1995)), en la Física (templado estadístico, más conocido en inglés, *simulated annealing*)...

La Inteligencia Computacional recoge todos estos conceptos de una búsqueda de la replicación de inteligencia de una forma **subsimbólica**, conexionista, sintética, evolutiva y distribuida,

2.7. La Robótica en la Inteligencia Artificial

La Robótica es el conjunto de técnicas que se desarrollan a partir de un numeroso conjunto de áreas de conocimiento, y que tienen como objetivo construir sistemas con algún grado de libertad⁷ que lleven a cabo tareas de manipulación o simple observación y recogida de datos de su entorno. Dichos sistemas no entran dentro de la clasificación de herramientas por presentar múltiples aplicaciones y flexibilidad para llevar a cabo un gran número de tareas diferentes. Podríamos decir que son más que simples ayudas con un uso determinado para poder manipular objetos que con nuestro cuerpo es más difícil o imposible, o se produce un resultado peor.

Una de las características que más nos sorprende a los humanos es que otros animales, principalmente otros primates, también sean capaces de usar herramientas, e incluso idearlas, extraerlas de su entorno. El humano ha sido capaz de usar unas herramientas para construir otras mejores, y pasar esa difusa frontera que las convierte en robots, brazos robotizados, o cualquier otra expresión que ayude a señalarlos.

El objetivo de estos robots es idéntico a la mayor parte de objetivos que tiene el ser humano, para bien o para mal transformar su entorno para hacer su vida más cómoda, con menos esfuerzo, aunque como consecuencia de este proceso se llegue a que las soluciones creen más necesidades, como en cualquier sistema evolutivo.

Dice Román Gubern (1987) en *El simio informatizado* que el sueño del ser humano ha sido siempre crear un ser a su imagen y semejanza, y en primer lugar a través de la imagen, con la pintura y escultura, el paso más sencillo. Cuando la tecnología lo permitió creó los autómatas, por ejemplo el de Torres-Quevedo. Hace relativamente poco con la Inteligencia Artificial llegó al objetivo de copiar la inteligencia humana. Y es ahora cuando se llega al último paso que completa la creación humana: el mito de Golem, Frankenstein y otros muchos más se empiezan a acercar a la tecnología con la Robótica Autónoma.

Podríamos decir que un robot sin “cerebro” es una escultura o una herramienta. El Dr. Rodolfo Llinás⁸ indica como origen del sistema nervioso la ventaja evolutiva de moverse con un objetivo, con la intención de llegar a un punto determinado. La necesidad es para producir el movimiento como para predecir el movimiento del entorno.

La Robótica ha obtenido importantes éxitos en campos como la automatización de procesos, la manipulación de objetos, pero en el campo de los entornos no estructurados no ha conseguido resultados que demuestren que el acercamiento usado sea válido, y por tanto, que impulsen su desarrollo e investigación en el mismo. Esto es debido

⁷ Los grados de libertad (*degrees of freedom*) son el número de parámetros necesarios para describir el estado o la posición del sistema, y está directamente relacionado con el número de ejes, articulaciones y motores.

⁸Neurólogo y director del depto. de Neurología de la Universidad de Nueva York entrevistado en el programa Redes de Eduard Punset (<http://www.rtve.es/tve/b/redes/semanal/prg233/entrevista.htm>)

a que se han usado aproximaciones basadas en un diseño descendente integrado en la Inteligencia Artificial (como se discute en la sección 2.8).

Con la expresión *entornos no estructurados* se indica que el entorno no está preparado especialmente para el funcionamiento del robot, y que puede cambiar de forma imprevista y abierta. En otras palabras, el entorno no se puede describir en una estructura de datos que pueda usar el robot por ser muy cambiante o por no disponer de información precisa. Por esto un modelo interno del mundo no le serviría para desarrollar su tarea, así que toma vital importancia la adquisición instantánea de información a través de los sensores externos e internos, la inmediata reacción, y la previsión del efecto del robot sobre sí mismo y sobre su entorno.

2.8. Problemas fundamentales de la Inteligencia Artificial en la Robótica

Muchos trabajos de investigación usan el término **GOFAI**⁹ porque tienen en consideración el “problema de basarse en símbolos” (*symbol grounding problem*) que se opone a la hipótesis del sistema de símbolos (ver el punto 2.4.1). El *problema de basarse en símbolos* plantea la necesidad de la existencia de lo físico para generar significados. Los símbolos sólo tienen sentido al considerar sus relaciones con elementos materiales. Un ciego de nacimiento conoce la palabra “color” pero para él no tiene ningún sentido.

Por ello muchos investigadores abogan por una Inteligencia Artificial basada en la hipótesis de la base física (*physical grounding hypothesis*), una Inteligencia Artificial que Brooks denomina “*Nouvelle AI*” (Brooks, 1990) en contraposición a la IA clásica. En esta hipótesis el sistema maneja representaciones basadas en el mundo físico. Centrándonos en la Robótica, cada número que cuantifica la intensidad de una señal tiene sentido porque está relacionado (directa o indirectamente) con la física del sensor del que procede la lectura de datos. Para avanzar hacia la obtención de inteligencia es necesario *integrar* el sistema en un entorno al que se debe adaptar desarrollando capacidades que unen de forma inseparable la percepción, la planificación y la acción motora. Tanto la percepción como la motricidad son también inseparables de una determinada forma física. A esta característica se la denomina *corporeidad*. Estas ideas son fundamentales en la *revolución robótica*, de la que trataremos en la sección 2.9.

La Inteligencia Artificial ha realizado un buen trabajo en problemas en los que el planteamiento simbólico y el **Conexionismo light** (que busca correlaciones en su base de datos) son adecuados. Más concretamente, en los se trata del manejo de información como en los sistemas expertos, o en los que la entrada se compone de números “etiquetados”, como los metros cuadrados de la vivienda, o de símbolos, por ejemplo si su calidad es mala, normal o buena.

Algunos autores (los menos) que trabajan en la Inteligencia Artificial consideran la visión clásica de la misma como la única forma de desarrollar robots y de usar las redes neuronales y estructuras afines (Mira, 2006). Esto se debe a que la Inteligencia Artificial clásica tiene una larga historia en la que ha recibido más financiación y atención, y por ello tiene más peso e intenta abarcar más problemas de lo que es razonable para el **paradigma**. Este comportamiento es herencia del ánimo generado en la época dorada. Sin embargo ahora y como señala Alonso (2006), la Inteligencia Artificial se balancea en lo positivo del *test de Turing* (Turing, 1950) y lo negativo de la *habitación china* (Searle, 1980), metáforas ya descritas en la sección 2.3.

Tradicionalmente la Inteligencia Artificial ha asumido la investigación en Robótica por la suposición de que los robots deben tener inteligencia. Para ello se toma una definición antropocéntrica de la inteligencia, si bien a veces se cede condescendentemente a los grandes simios ciertas capacidades inteligentes. Pero esto depende de la

⁹Haugeland (1985) acuñó el acrónimo GOFAI (*Gold Old-Fashioned Artificial Intelligence*, la Inteligencia Artificial pasada de moda) para indicar el apego de la Inteligencia Artificial a lo simbólico y sugiriendo que es una opción desfasada en cierto tipo de problemas, como los de Robótica. También se suele denominar Inteligencia Artificial clásica.

concepción de inteligencia. También existe la variante de pensar que un comportamiento es inteligente cuando nos parece difícil para lo que se puede esperar del ser vivo. Pongamos por ejemplo que la cría de cualquier pequeño mamífero sabe encontrar la mama, e incluso la forma de organizarse un hormiguero o colmena. De hecho, se llega a definir inteligencia como cualquier comportamiento adaptativo del ser humano, como por ejemplo mantener el equilibrio. Sin embargo, no queda claro si la capacidad de volar de las aves es inteligencia o habilidad (Fernández-Caballero, 2006).

La GOFAI le ha proporcionado a la Robótica sistemas de control diseñados directamente por un programador y asumiendo que el robot tuviera que funcionar en entornos altamente estructurados y estables con el fin de mantener un modelo interior del mundo. Solamente tiene en cuenta el aspecto abstracto y se supone que el sistema inteligente puede controlar el robot. Posteriormente estos planteamientos han cambiado, ya que se necesitaba trabajar en entornos no estructurados en los que la Inteligencia Artificial clásica da resultados con mucho esfuerzo y restricciones (viajes espaciales, tareas peligrosas, imposibilidad de control remoto, como se indica en la sección 2.7). Aun así, la idea de mantener el control sobre el procesamiento de los datos provenientes de los sensores se ha mantenido con el planteamiento Sentir-Modelar-Planear-Actuar (SMPA). Pero resolver estos problemas en ese marco resulta difícil, por lo que Brooks propuso su Arquitectura de Subsunción (véase el punto 2.9.1).

2.9. La revolución robótica

En esta sección se describen conceptos que no se tienen en cuenta en la Robótica basada en la GOFAI, y que tienen como consecuencia trabajos en Robótica en los que se produce de una forma relativamente fácil comportamientos adaptativos, que si bien muchos no les darían el calificativo de inteligentes, son una base a partir de la que se ha desarrollado la inteligencia en los seres vivos. Un comportamiento adaptativo es la capacidad de un sistema de reaccionar ante diferentes tipos de configuraciones del entorno dando una respuesta adecuada, de tal forma que mejora la situación de dicho sistema.

2.9.1. Rodney Brooks. Corporeidad y ubicación

La Robótica que trabaja con los planteamientos de la Inteligencia Artificial clásica crea sistemas de razonamiento simbólico *alojados* en un robot, separado de la interacción *sensomotora* con el entorno ya que los sensores proporcionan información simbólica y las órdenes a los motores también son símbolos (Russell y Norvig, 1994). El sistema funciona independientemente del dominio, y sólo cuando el observador asigna el significado a los símbolos el sistema entero toma sentido, está bien fundado o basado (*grounded*). El sistema funcionará correctamente mientras la información codificada en esos símbolos sea coherente, independientemente de su significado. Sólo el observador le da un significado completo al sistema al añadir su propia experiencia. Brooks afirma: “[*central representations are not necessary and appear only in the eye or mind of the observer*]” (*las representaciones centrales no son necesarias y sólo aparecen en el ojo o en la mente del observador*) (Brooks, 1991b) e “[*Intelligence is in the eye of the observer*]” (*la inteligencia está en el ojo del observador*) (Brooks, 1991a).

Esta visión basada en la separación entre lo *sensomotor* y lo planificador tiene como origen el *dualismo* cartesiano. Brooks¹⁰ plantea una *revolución* con su *Elephants don't play chess* (Brooks, 1990). En este artículo con tan provocativo título (que une el mayor éxito de la Inteligencia Artificial, el ajedrez, con la corpulencia y proverbial

¹⁰En <http://people.csail.mit.edu/brooks/> se lee su biografía. Entre otras cosas, “Rodney Brooks is Panasonic Professor of Robotics in the Electrical Engineering & Computer Science Department (EECS) at the Massachusetts Institute of Technology (MIT). He was Director of the Computer Science and Artificial Intelligence Laboratory (CSAIL).”. También se puede disfrutar de una entrevista divulgativa del gran comunicador Eduard Punset en http://www.eduardpunset.es/charlascon_detalle.php?id=18

memoria del elefante) describe los objetivos de la *Inteligencia Artificial tradicional* y de la *Nouvelle AI*, la primera basada en el razonamiento y la segunda basada en la *corporeidad*, en lo percibido.

Brooks afirma que la inteligencia requiere *ubicación* (*situatedness*) y *corporeidad* (*embodiment*) (Brooks, 1991b, 1990, 1991a). Un sistema está ubicado (*situated*) si no maneja descripciones abstractas del mundo (a no ser que el mecanismo para hacerlo haya surgido de la interacción entre las partes del sistema). El agente debe operar en el mundo real y solucionar problemas que ocurren en una dimensión temporal. Un sistema corporeizado (*embodied*) depende de la influencia de su propio cuerpo físico interactuando con el entorno.

En la *Nouvelle* Inteligencia Artificial Brooks desarrolló su Arquitectura de Subsunción (Brooks, 1991b), invalidando la aproximación basada en romper el ciclo en las fases *sentir-modelar-planear-actuar*. De esa forma el propio mundo es el mejor modelo. El sistema se construye de abajo hacia arriba. El significado de cada parte del sistema se basa en el entorno y no hay símbolos generados por el ser humano. Los símbolos del sistema *emergen* de la dinámica del sistema, y no están definidos en el diseño¹¹. A partir del planteamiento de la arquitectura de subsunción se ha seguido trabajando en la robótica, por ejemplo con la estructura de multiagentes en la que módulos compiten por el control del robot en cada instante, y un árbitro decide cuál *pilota* (Nebot y Cervera, 2006).

2.9.2. Inspiración biológica: la Robótica basada en la Vida Artificial

A finales de los ochenta la Inteligencia Artificial no era capaz de afrontar problemas que no se basaran en el razonamiento abstracto y la lógica, del tipo de los Sistemas Expertos. En esta situación se replanteó el estudio de la Inteligencia desde arriba, desde un punto de vista antropocéntrico, y se pensó en el estudio de la vida, como un medio para estudiar la Inteligencia desde abajo, y como un fin para estudiar los mecanismos que caracterizan e intervienen en los seres vivos (Meyer y Wilson, 1991). Esta disciplina que estudia la vida, llamada Vida Artificial, es un área de investigación reciente (Langton, 1989; Langton et al., 1991; Fernández Ostolaza y Moreno, 1992; Etxeberria, 1995) que estudia los sistemas artificiales en los que se puede observar una evolución análoga a la de sistemas biológicos del mundo real. El Programa de Investigación de la Vida Artificial puede, en cierto sentido, contribuir a la solución de problemas fundamentales de la Inteligencia Artificial, dado que su planteamiento es mucho más radicalmente “de-abajo-a-arriba” que el de la Inteligencia Artificial. De hecho, en Inteligencia Artificial aún persiste el problema de cómo proporcionar flexibilidad en sus sistemas para cambiar e integrar nueva información sin intervención humana, ya que la estructura del sistema está completamente definida por diseño. Sin embargo la Vida Artificial encaja la evolución del sistema en un entorno, y su adaptación a dicho entorno le proporciona la característica de la *autoorganización*. Otra diferencia importante es el nivel de abstracción de la inteligencia: en Inteligencia Artificial se pretende diseñar una pequeña parte a un nivel de abstracción alto, mientras que en Vida Artificial se hace evolucionar todo el sistema a un nivel bajo, con lo que se consigue una mayor flexibilidad. Precisamente, la imposibilidad de un diseño a mano con determinados requerimientos obliga a usar este esquema. La Vida Artificial encaja perfectamente con la idea de Brooks (1990), ya que la Vida Artificial usa el mismo concepto de *corporeidad* y *ubicación* (ver el punto 2.9.1).

El Programa de Investigación de la Vida Artificial comprende varios campos: Biología Teórica (evolución prebiótica, origen de la vida, evolución del metabolismo, comportamiento colectivo), Robótica Adaptativa y Evolutiva (algoritmos genéticos, redes neuronales, programación genética, sistemas autónomos, optimización de procesos, procesos autoorganizativos) y el desarrollo de simulaciones computacionales de comportamientos parecidos a los de los organismos vivos (*lifelike*). Los resultados en esta última área se pueden, generalmente, aplicar en las demás.

¹¹Últimamente se habla mucho de las emociones de los robots. En algunos casos da la impresión de que los sistemas son tan fáciles y tan absurdos como programar esta instrucción si (nivelbatería>75%) entonces estadoanímico=contento. ¿Tiene esto sentido? Sólo es necesario compararlo con el comportamiento de un bebé después de su biberón.

Existen múltiples consideraciones en torno a la Vida Artificial que marcan distintas vías, como la Vida Artificial Fuerte (Moreno y González-Nalda, 1997), en la que si un sistema generado en simulación muestra características que relacionamos con los seres vivos que conocemos, entonces a dicho sistema lo consideramos un ser vivo *sintético*.

2.9.3. La Caja de Skinner y el concepto de Autonomía en la Vida Artificial

En la Vida Artificial se pueden usar técnicas pensadas para experimentos de Psicología Animal, como el clásico experimento de la *caja de Skinner* (Skinner, 1938), en el que una rata en una caja debe (o puede) pulsar una palanca u otra. Las ratas aprenden a relacionar el premio o castigo que reciben al apretar una palanca con el estímulo asociado a la palanca (una luz, una imagen, un sonido).

Una de las principales características de la vida es que un ser vivo es *autónomo* con respecto a su entorno, con el objetivo del automantenimiento. Ésta es precisamente una característica importante en la Robótica, cuando se trata de que el robot sea capaz de enfrentarse a un entorno cambiante. Se denomina Robótica Autónoma al desarrollo de sistemas robotizados, automáticos, que sean capaces de actuar en entornos no estructurados sin intervención directa humana, por lo menos en la mayor parte de su funcionamiento, o lo que es lo mismo, la obtención de robots con dicha característica de autonomía. Sin entrar en los amplios debates por lo indefinido de este difícil término, la autonomía en este caso es la capacidad del robot de no depender del control humano para mantenerse y desarrollar ciertas tareas en entornos no estructurados (ver la sección 2.7).

Como en todas las definiciones que pretenden establecer límites entre objetos, se podrían señalar problemas al determinar si es verdaderamente un robot autónomo el robot con control remoto que opera en situaciones en las que un ser humano tiene peligro, o el que necesita supervisión para la carga de baterías. Pero en esto como en su distinción con una herramienta hay fronteras borrosas, y puede ser tan extraño como afirmar que, ya que un humano recién nacido es tan dependiente de sus padres para satisfacer sus necesidades vitales, no es un ser vivo.

Esta comparación nos da idea del paralelismo entre los seres vivos, entidades con un alto grado de independencia respecto al entorno, y los robots autónomos, que también presentan esta situación.

2.9.4. Walter y Braitenberg

En Robótica el problema es cómo controlar los mecanismos robotizados, cómo obtener un mecanismo controlador de esa herramienta compleja que es el cuerpo del robot. Una forma de empezar es analizar los trabajos de Braitenberg (1984) y Walter (1950, 1951), de mucho impacto en la Robótica Autónoma, ya que son los primeros en el área de la Cibernética aplicables a la Robótica. Este campo se convierte en una disciplina firmemente establecida con el trabajo de Wiener (1948) y su concepto principal es el de *retroalimentación* (se usa mucho la palabra inglesa, *feedback*). Las Tortugas de Walter son lo que se podría denominar el primer robot, ya que se autocontrolaban y dirigían funcionando en un esquema cibernético. Los vehículos de Braitenberg (el libro de Braitenberg, 1984, titulado *Vehicles*) son experimentos mentales que implementan en robots virtuales lo que en Biología se denominan *tropismos* y *taxis*, las acciones más básicas que puede tener un ser vivo, incluso aparecen en el crecimiento de los vegetales. El vehículo de Braitenberg más interesante se dirige a una fuente que estimula los sensores, por ejemplo una fuente de luz y sensores basados en células fotoeléctricas. Se denomina fototaxia positiva, y sería un simple mecanismo cableado (*hardwired*) simétrico en el que un aumento del estímulo en la célula izquierda aceleraría el motor derecho y viceversa, con lo que el vehículo se mueve hacia la fuente de luz¹².

¹²Di Paolo (2003b) considera “desafiante” que Braitenberg califique al robot de la figura 2.1 como el que representa al “amor”. Lo une al eterno problema de atribuir comportamientos emocionales a seres artificiales, paralelo a asignarle inteligencia.




Figura 2.1: Vehículo de Braitenberg 2b.

En la Robótica Autónoma hay trabajos que desarrollan vehículos de Braitenberg que usan luz blanca en robots de dos ruedas (Scutt, 1994). El aparentemente simple planteamiento teórico de Braitenberg es analizado y aumentado en el trabajo de Scutt, primero construyéndolo en la práctica y comprobando que no sólo se dirige hacia la luz sino que evita obstáculos debido a que se aparta de las zonas sombrías que producen los objetos. Este comportamiento se puede escapar de nuestro análisis por ser una consecuencia no demasiado clara. En un experimento posterior crea un simple controlador con cinco neuronas, que desde un punto de equilibrio inestable evoluciona hacia el vehículo de Braitenberg antes descrito mediante el condicionamiento clásico y la habituación de las sinapsis neuronales. Para que esto sea posible se crean dichas neuronas como un modelo directo de las neuronas biológicas, con sus característicos niveles eléctricos. Las conexiones directas (sensor izquierdo a motor izquierdo) se debilitan porque apartan de la luz, mientras que las cruzadas se refuerzan, al acercarse a la luz. Esto se debe a que el disparo que acerca a la luz refuerza la sinapsis con el posterior estímulo lumínico más intenso.

Hay también algunos diseños que usan sonido en vez de luz, como los que emulan la [fonotaxia](#) del grillo en robots que reconocen el canto de un grillo de una especie determinada, cuatro ráfagas de 20 ms de una onda de 4'8 kHz (Lund et al., 1997; Horchler et al., 2003). La mayor parte de los trabajos desarrollados hasta el momento usan señales simples y constantes como estímulos. Sin embargo, algunos artículos (Yamauchi y Beer, 1994) presentan avances, que usa una distancia a un objeto para distinguir cuál de los dos posibles es, y estudian la capacidad de distinguir secuencias de hasta tres bits. Floreano y Mattiussi (2001) subrayan la dificultad de reconocer señales complejas que varían en el tiempo, y preparan un pequeño robot de dos ruedas (Khepera) que permite que no choque con paredes pintadas con franjas verticales, que parecen código de barras. Suzuki y Floreano (2006) desarrollan en simulación un robot que determina hacia dónde debe girar en función de la posición de dos cuadrados en las paredes, cuadrados que no puede ver simultáneamente.

2.9.5. Robótica Evolutiva

En el marco de la Vida Artificial se pueden diseñar sistemas con una dinámica compleja en la que a través de la [autoorganización](#) emergen estructuras, funciones y comportamientos que proveen al robot de capacidades que lo clasifican como vivo bajo la visión de la Vida Artificial Fuerte. Yendo más allá, el comportamiento adaptativo de ese “ser vivo” podría ser calificado como inteligente bajo la visión de un Test de Turing (1950), y más resistente a la de la Habitación China de Searle (1980) (ver la sección 2.3).

Si se introduce en este esquema la Neurociencia Computacional (disciplina que estudia las características de las neuronas y sus interacción con el uso de ordenadores, y que está representada por revistas como *Neurocomputing*

(González-Nalda y Cases, 2008) y con ello se produce un robot controlado por neuronas artificiales que modelan el funcionamiento de las neuronas naturales, se obtiene un marco adecuado para aplicar las [Neurociencias](#) a la Ingeniería y obtener robots que realizan tareas basados en la Vida Artificial.

El problema es cómo diseñar un robot con una estructura emergente, cómo obtener sus características tanto cualitativas como cuantitativas. Para ello se usan los algoritmos evolutivos, mecanismos que abstraen las complejidades de los sistemas evolutivos naturales y aplican la evolución a los individuos a través de sus características.

De la misma forma que los humanos han seleccionado las vacas con el fin de optimizar su cantidad de leche o su calidad de carnes, la evolución permite obtener individuos (robots) adecuados a nuestro objetivo. Para ello se codifica todo lo modificable de un robot en una estructura de datos, el gen. Se genera una población en parte o totalmente aleatoria, se evalúa cómo se adecúa cada individuo al *fin* deseado, y se mezclan los datos de dos o más individuos que han dado buena puntuación en la prueba para tener una nueva generación.

La aplicación de los algoritmos genéticos a la Robótica es una moderna disciplina llamada Robótica Evolutiva, y lo habitual es usar con ella los conceptos de las [Neurociencias](#).

Análisis de la Robótica Evolutiva

En este capítulo se describen las bases y los principios metodológicos e ingenieriles en las que se construye la Robótica Evolutiva, sus variantes, los resultados más característicos, y sus límites y problemas más importantes.

3.1. Objetivos y motivaciones específicos de la Robótica Evolutiva

Se cita en muchos trabajos (principalmente Brooks, 1991b) la gran dificultad de diseñar sistemas de control de robots autónomos, sobre todo si el trabajo sigue una visión emergente, en la que se quiere evitar trabajar con sistemas simbólicos. En este caso resulta natural inspirarse en la Teoría de la Evolución de Darwin (1859) para seleccionar el control del robot mediante selección artificial. Esta forma de trabajar se denomina Robótica Evolutiva, una disciplina muy joven fundada básicamente con los trabajos de Brooks (1990), Koza (1992), Floreano y Mondada (1994b), Harvey, Husbands y Cliff (1994). El término *Robótica Evolutiva* fue introducido por Peter Cariani en 1987 en un trabajo no publicado, según explican Harvey, Di Paolo, Wood, Quinn y Tuci (2005). En este texto del grupo de Sussex y la tesis de Jakobi (1998) se puede encontrar una historia de la Robótica Evolutiva. Una interesante revisión de la disciplina también se encuentra en el primer capítulo del libro de Wang et al. (2006).

Se puede definir la Robótica Evolutiva como la técnica que busca la obtención del controlador (y a veces la forma) de robots para que desarrollen ciertas tareas, a través de mecanismos evolutivos inspirados en la Evolución y en la Genética. Esta definición es de mínimos, ya que está dada en base al objetivo y el medio imprescindible para que sea calificada de evolutiva. Por ahora la Robótica Evolutiva es el conjunto de aproximaciones a este problema, ya sea a través de Programación Genética, de Arquitectura de Subsunción combinada con Programación Genética, de Redes Neuronales, o sistemas mixtos, combinando aproximaciones, con el fin de acercarse lo posible a la resolución de una tarea concreta por un robot determinado.

Una definición alternativa es la dada por Gomi y Griffith (1996) en la que se plantea la Robótica Evolutiva como

la aplicación de técnicas de la Vida Artificial a la Robótica Basada en el Comportamiento (véase Brooks, 1991a). Las posibles definiciones de la Robótica Evolutiva llegan prácticamente a lo mismo, ya que muchas técnicas que diferencian y caracterizan a la Vida Artificial son evolutivas (el cambio en el tiempo es necesario para que emerjan estructuras debido a procesos de [autoorganización](#)), y la Robótica Basada en el Comportamiento es la Robótica de los entornos no estructurados (por ser necesarios los comportamientos complejos para funcionar en situaciones en las que no se pueden usar modelos del mundo). Por tanto, se puede decir que en realidad no existe más definición que la que lo delimita exclusivamente por unos mínimos que producen una denominación común.

La Robótica Evolutiva se puede considerar englobada dentro de la Robótica Autónoma y ésta en la Robótica Basada en el Comportamiento (Lazkano Ortega, 2004), aunque como ya se ha dicho es posible otras clasificaciones (Wang et al., 2006). Faltaría marcar una clara diferencia entre estas dos últimas, ya que si tenemos en cuenta la definición de autonomía dada en el capítulo anterior, el robot es autónomo con respecto a su entorno cambiante con el objetivo de su mantenimiento. Para ello debería tener un comportamiento independiente, no determinado directamente por su entorno (un remolino de agua en un río no es autónomo), sino que debería desarrollar diferentes comportamientos.

La Robótica Evolutiva es pues un método de desarrollo de robots que aprovecha mecanismos evolutivos para la obtención de parte o todo el robot. Dichos algoritmos evolutivos se inspiran en diversas teorías que se encuentran en la Biología Evolutiva, aparte de otros mecanismos optimizadores extraídos de la Física, como el templado estadístico (*simulated annealing*), que ha sido incluido en la teoría de las Redes Neuronales.

Se puede trabajar en Robótica Evolutiva desde las asunciones de la Inteligencia Artificial clásica (simbólica), pero el resultado es más difícil de manejar conceptualmente. El entorno proporcionado por la inspiración biológica y los conceptos presentados en la última sección del capítulo anterior facilita el trabajo (ver la sección 1.1).

Los objetos sobre los que actúa esa evolución pueden ser varios: programas, parámetros, hardware, reglas de sistemas expertos, redes neuronales... y normalmente constituyen el sistema controlador del robot, y en muy contados casos la forma del robot o de sus sensores o efectores. Depende del planteamiento con el que se aborda el problema se busca obtener solamente el controlador adecuado para un robot, o se evoluciona de forma integral para que encaje en su entorno. Resulta evidente la dificultad de este segundo planteamiento, la evolución de la forma, comparándolo con evolucionar solamente estructuras de datos o programas LISP. El porqué de afrontar una evolución tan compleja es que debe equipararse con el problema que se quiere resolver (Brooks, 1991b).

En la bibliografía de la Robótica Evolutiva no se ponen trabas a las técnicas y métodos secundarios para la obtención del robot. Esto es debido a que, por su juventud, se trata de una técnica sin una ciencia que la avale y estructure (más bien es entonces una *artesanía*). La teoría matemática aplicable en los problemas de Robótica Evolutiva, que incluye la que describe la dinámica de Redes Neuronales y Algoritmos Genéticos a través de ecuaciones diferenciales parciales, es de poca ayuda. Lo único que puede establecer unas normas es el trabajo realizado en la Filosofía de la Biología para desarrollar una estructura teórica. Las técnicas desarrolladas en los diferentes trabajos permiten elegir los componentes necesarios para construir los sistemas. Se puede poner como ejemplo el trabajo sobre la aerodinámica de los Fórmula 1. Por mucho que sepan de teoría los ingenieros del equipo, al final necesitan túneles de viento y simulaciones computacionales de los mismos para desarrollar mediante aproximaciones sucesivas una solución adecuada para el circuito. Una pequeña aleta en el *fuselaje* pasa por las fases de diseño mental, diseño en papel, diseño en ordenador, simulación de túnel de viento en ordenador, túnel de viento (según el presupuesto del equipo), y prueba del piloto en pista. En Robótica Evolutiva se hace parecido, pero muchas veces no se pasa de la simulación a la realidad porque todavía se necesitan más mejoras en simulación que suponen saltos drásticos, necesarios para obtener capacidades básicas.

Hay muchas disciplinas que basan su conocimiento en la técnica del ensayo y error, en la que se hacen prototi-

pos de máquinas por ser imposible predecir su comportamiento, y en base a los resultados se plantean teorías que se toman como ciertas mientras son consistentes cuando se enfrentan a los nuevos resultados.

En los primeros años de la Robótica Evolutiva, se evaluaban y justificaban métodos variados, y el propio hecho de la evolución de robots era justificado ante otros. Los trabajos de Harvey et al. (1992), Cliff, Harvey y Husbands (1993) y Harvey (1995) justifican la evolución contra el diseño, y se considera la aproximación incremental al problema de la Robótica. Posteriormente se evalúan las ventajas de evolucionar programas, funciones matemáticas o Redes Neuronales.

En los últimos años ha habido una deriva a los análisis teóricos frente a los desarrollos técnicos o de ingeniería, evolución que se puede atribuir a la creciente dificultad de abordar tareas y comportamientos cada vez más complicados, parón técnico que también ha ocurrido en el enfoque clásico de la Robótica basada en la GOFAI (ver la sección 2.8), en los que las tareas de seguimiento de un elemento perceptivo simple y previamente determinado (por ejemplo, una camiseta verde intenso en un entorno con ausencia de verdes) es un problema habitual.

En el artículo de Harvey, Di Paolo, Wood, Quinn y Tuci (2005) se plantea la Robótica Evolutiva como una herramienta para estudiar la cognición. Es decir, se obtienen robots que exhiben capacidades cognitivas, que conforme se van obteniendo en un mismo robot, se puede obtener un comportamiento *útil*, es decir, un resultado en el aspecto de la ingeniería.

Un aspecto interesante que describe Jakobi (1998) es la separación de comportamientos en función de las redes neuronales que se usan para abordarlos: comportamientos reactivos, no reactivos y simples, y no reactivos y dinámicamente complejos. En ésta última categoría justifica la necesidad de usar redes neuronales que manejen dinámicas temporales complejas.

3.2. Situación actual de la Robótica Evolutiva

En la actualidad se publican pocos trabajos encuadrados en la Robótica Evolutiva. Esto es debido a que, sin un adecuado mecanismo **morfogenético**, los sistemas no son escalables y los comportamientos que se pueden obtener son sencillos, como las **taxias**. Esto no quiere decir que carezcan de interés, sino que el estudio de taxias se restringe a unos objetivos muy concretos, sobre todo a la simulación de capacidades cognitivas de seres vivos, trabajo muy interesante para la Filosofía de la Biología. En el resto de objetivos de la Robótica Evolutiva, el objetivo consiste entonces en conseguir un sistema perceptivo complejo que asocie estímulos con respuestas, y un sistema motor complejo. Un sistema de control de un robot debería contener además subsistemas propioceptivos e **interoceptivo**, que en los seres vivos perciben respectivamente la posición del cuerpo y las propias vísceras, los órganos internos.

El problema es que la Robótica Evolutiva necesita un cambio cualitativo para el que falta una base. Esta base previa debería mostrar un entorno en el que la morfogénesis, aun sin ser necesaria, daría una flexibilidad añadida. Sin la morfogénesis tenemos un esquema en el que los comportamientos son estáticos, ajustados a un determinado entorno también de estructura inmóvil (aunque sus partes puedan tener un determinado cambio).

Se puede hacer una relación de tendencias y grupos históricos en la Robótica Evolutiva (ver más adelante en esta sección). Del trabajo actual es destacable el de Ezequiel Di Paolo (Di Paolo, 2003a,b), que trabaja junto a Inman Harvey y Rachel Wood (Harvey et al., 2005). Uno de sus puntos fuertes es que intenta enlazar las **Neurociencias** con la Robótica Evolutiva, y una gran visión general de la disciplina, que le permite publicar revisiones de libros (Di Paolo, 2002) de *pesos pesados* como Nolfi y Floreano (2001). En la revisión de este libro Di Paolo dice:

“Today, the current direction of much work in ER is not so much ‘upward’ in the scale of complexity, but ‘inward’ in the detailed understanding of the relations between the structure of behaviour and

the spatio-temporal structure of dynamical controllers as well as their overall relation to evolvability and fitness function design.”

Dicho de otra manera, no se suele buscar componer diferentes elementos ya estudiados para obtener más complejidad, sino estudiar detalladamente la dinámica e interacción entre ellos. En la misma página indica como mayor problema de un punto de vista técnico el comportamiento de la evolución de *aprovecharse* de contingencias del entorno en el que actúa el algoritmo genético. También incide en la dificultad del análisis de lo evolucionado, que es menos que estudiar a los propios seres vivos.

Otra frase muy interesante de la revisión es:

“Designing a working robot by hand for interesting, non-trivial and robust behaviour is an increasingly hopeless task. This alone would justify some sort of automatic synthetic process like ER on practical grounds.”

Lo dice como introducción al razonamiento de que la Robótica Evolutiva es interesante para el estudio de la cognición y para romper con preconcepciones de cómo son las cosas. Sin embargo, esta frase simplemente dice que el diseño a mano de robots es inviable conforme crecen las interacciones, y que esta idea justifica estos medios por cuestiones prácticas.

Finalmente, afirma:

“The purpose of work in ER is less centred on trying to obtain more ‘cognitively’ complex performance —a goal that has not been abandoned— and more on understanding other dimensions of adaptation and the role of different kinds of underlying mechanisms. The design and study of novel integrated systems of this sort may well be one way for evolutionary robotics to contribute useful information back to biology, especially neuroscience, in the proximate future.”

Es decir, no se ha abandonado (aunque lo parezca) el trabajo en comportamientos cada vez más complejos, y el diseño de sistemas que los produzcan puede contribuir con información a las [Neurociencias](#) principalmente.

3.3. Grupos básicos en Robótica Evolutiva

De todos los grupos que han trabajado en la Robótica Evolutiva, en el análisis del “estado del arte” del área llevado a cabo por Matarić y Cliff (1996) destacan por el peso e influencia de su trabajo a los siguientes grupos y personas, de los que se describe su trabajo a continuación.

3.3.1. John Koza

Como hemos comentado, John Koza es el fundador de la Programación Genética (Koza, 1992), esta rama de la Programación Evolutiva, y la ha aplicado en la Robótica. Se basa en la evolución de programas de estructura similar al LISP, con operaciones típicas de los Algoritmos Genéticos, como la mutación y el cruce, adaptadas a dicha estructura. Dichos programas pueden tener como funciones operaciones de alto nivel controladas por capas de una Arquitectura de Subsunción, o una Máquina de Estados Finitos, o cualquier tipo de tarea sensorial o motora. Koza ha realizado simulaciones de seguimiento de paredes con controladores de robots desarrollados con Programación Genética. Brooks objeta que estos éxitos obtenidos en simulaciones no son trasladables a realizaciones, debido a la

drástica simplificación de los posibles sensores (en cuanto a tamaño y forma, con información exacta, instantánea) y del propio robot, que en la simulación es un simple punto que rebota en las paredes de forma lineal y perfecta. A partir de esto, es difícil valorar los resultados de las simulaciones. Se aleja además de un objetivo de la Robótica Evolutiva, que es no quedarse sólo en simulaciones.

3.3.2. Francesco Mondada y Dario Floreano

Estos investigadores han desarrollado varios trabajos que conjuntan Redes Neuronales con Algoritmos Genéticos (Floreano y Mondada, 1994b) (Floreano y Mondada, 1994a) (Floreano y Mondada, 1996). Han evolucionado un sistema de control de un robot *Khepera* que le permite navegar en un laberinto. El mismo robot *Khepera* ha sido desarrollado por Mondada. El sistema de control del robot está compuesto por una red neuronal que propaga la activación hacia adelante, denominadas *Feed Forward*, de dos capas con recursividad en la capa de salida. El genotipo del algoritmo genético que usan para obtener la red neuronal es la codificación de sus pesos. El *Khepera* está conectado a la estación de trabajo, donde se ejecuta el sistema de control. La función de adecuación premia la velocidad, la falta de fluctuaciones en el movimiento y el esquivar los obstáculos. Es de destacar que, al ser evolución en robot físico, sólo se le cede menos de un minuto a cada robot generado por el mecanismo evolutivo, así que el entorno de los robots es distinto, lo que no influye en la eficiencia de la evolución darwiniana que usa.

Es la primera evolución sobre robot físico con entradas y salidas físicas, sin ninguna simulación, y totalmente *situado* (integrado en el entorno) y *corporeizado* (ver el apartado 2.9.1). Muestra la capacidad que tiene el método evolutivo para obtener controladores en entornos cada vez más complejos.

Un resultado interesante del grupo que encabeza Dario Floreano en la *Ecole Polytechnique Fédérale de Lausanne (EPFL)* es la tesis doctoral de Mototaka Suzuki (2007). El trabajo de su tesis, dirigida por Dario Floreano también se presenta en (Suzuki y Floreano, 2006, 2008). Tiene puntos coincidentes con el que se presenta en esta memoria, pero está basado en visión y se usan señales “artificiales” consistentes en cuadrados negros sobre superficies blancas y no presenta una medida de eficacia absoluta de los individuos. La señal no varía si el individuo no mueve su cámara o sus ruedas. Este trabajo, por su especial interés, se analiza en el siguiente apartado.

3.3.3. Mototaka Suzuki

En este apartado se describe la reciente¹ tesis doctoral de Suzuki (2007), un ejemplo de sistema basado en visión que aborda un comportamiento y problema parecido al trabajo presentado en esta memoria. En concreto se compara la Red Neuronal y el experimento planteado en el capítulo 3.

3.3.3.1. Experimento y Red Neuronal

En dicho trabajo se plantea un recinto rectangular en el que hay dos cuadrados en dos paredes opuestas, de forma que pueda orientarse para llegar a una zona en una tercera pared (ver la figura 3.1). En el experimento no hay más maneras de identificar el objetivo que estas marcas visuales. El sistema de visión no puede percibir simultáneamente ambos cuadrados de una pared, con lo que la única forma de distinguir entre las dos configuraciones es percibir los dos cuadrados consecutivamente. Para ello debe mover la cámara tanto horizontal como verticalmente (*pan and tilt*, respectivamente) e integrar la detección en el tiempo de los dos cuadrados.

¹La tesis de Suzuki (2007) está publicada en diciembre de 2007 (ver <http://mototaka.googlepages.com/index.html>)




Figura 3.1: Experimento planteado en el trabajo de Suzuki (2007).

El sistema funciona con un modelo de red de neuronas *sigmoideas* (ver la sección 3.4.1) con una matriz bidimensional de cinco por cinco sensores y varias neuronas que controlan los efectores del robot, como se observa en la figura 3.2. Cada sensor tiene un *campo receptivo* cuadrado de 48 puntos de lado no solapado con los contiguos, y se puede controlar (con la neurona de filtrado) si su cantidad de activación depende de la media de todos los puntos o de la activación de únicamente el píxel central. Una neurona se activa si cualquiera de los 25 sensores se activa intensamente, de forma que indica que se está percibiendo la señal.

Una segunda neurona actúa como toda una capa interna que comunica los sensores con la capa asociativa. Esta capa recurrente también recibe las conexiones de la neurona detectora de objetos y de las unidades *propioceptivas*, que informan de la posición relativa de la cámara respecto al chasis del robot. Las salidas de las neuronas de la capa asociativa alimentan las entradas de las neuronas de la capa de salida: la neurona de filtrado, las dos de velocidad de cámara y las dos de velocidad de los motores (adelante si la activación es mayor de 0.5).

En cuanto al algoritmo genético, codifica los valores en una tira de bits y elimina el 80% de la población con peor valor de evaluación. Crea 78 individuos de la población de 100 a partir del cruce y mutación de los 20 restantes, y copia los dos mejores de la anterior generación para implementar una técnica elitista.

La función de adecuación (ver la sección 3.5) consiste en un bonus por realizar correctamente la tarea (y si

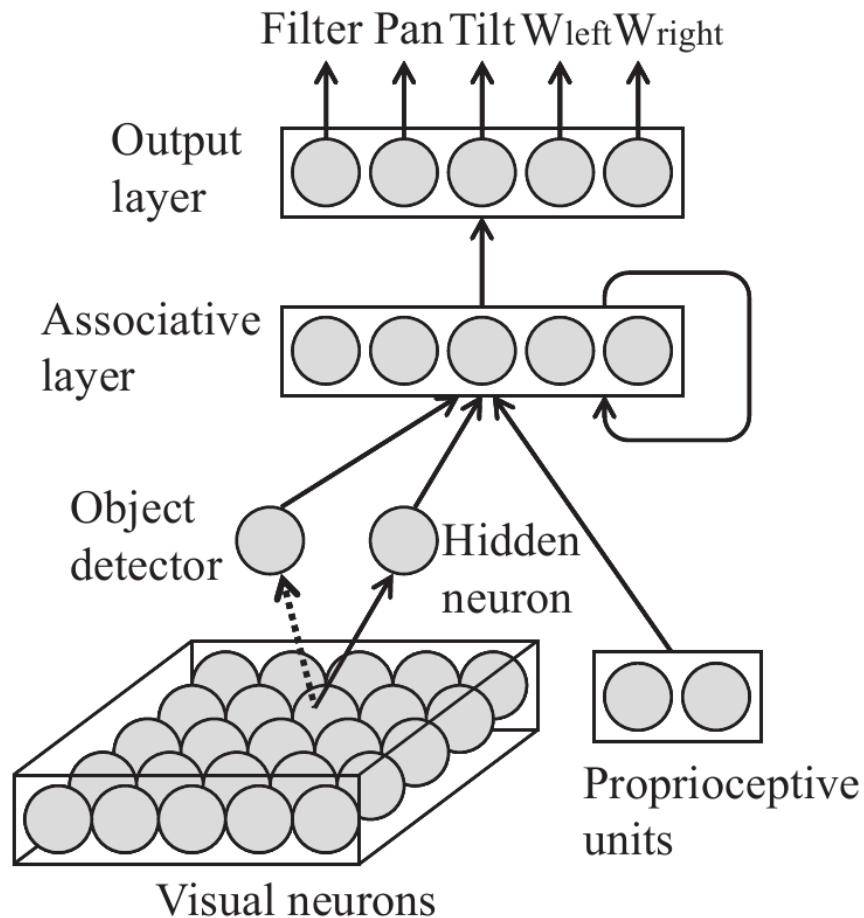


Figura 3.2: Red Neuronal diseñada para el trabajo de Suzuki (2007).

se ha detectado en la prueba un cuadrado inferior y otro superior). Para impulsar la evolución añade la media de la velocidad del individuo en cada una de las seis pruebas. Esta media se calcula con la suma de las velocidades instantáneas de los motores pero ponderando y disminuyendo esa suma con un valor proporcional a la diferencia de velocidades entre los motores. Si un motor va marcha atrás, el término no se usa para calcular la media de velocidad. En resumen, el valor de adecuación será mayor cuanto más tiempo pase el robot en línea recta y al máximo de velocidad, sin que penalicen los giros bruscos excepto en que no se aprovecha ese tiempo para sumar nada.

Al principio de cada una de las seis pruebas, el robot se coloca y orienta aleatoriamente en aproximadamente el centro del recinto.

3.3.3.2. Resultados

En el capítulo 3 de su tesis doctoral Suzuki (2007) analiza un individuo que alcanza la zona de acierto en las seis pruebas. La estrategia de este robot consiste en colocar la cámara a la altura de los cuadrados inferiores y girar hasta que encuentra uno. En cuanto lo detecta sube la cámara y gira en sentido contrario hasta encontrar el cuadrado superior. Dependiendo del tiempo que tarde en encontrarlo, el superior estará a la izquierda o a la derecha del inferior. En el caso de la posición incorrecta, volverá a girar hasta encontrar el otro cuadrado inferior. El robot

usa la visión activa para diferenciar las dos configuraciones, es decir, necesita el movimiento de la cámara para poder realizar la tarea.

Mediante la lesión de las neuronas detectora y oculta determina la necesidad de ambas, la primera para la parte temporal y la segunda para la visual. Si se realiza el experimento sin las neuronas propioceptivas los mejores individuos sólo pueden alcanzar la zona correcta en tres de las seis pruebas, ya que siempre van hacia la izquierda hayan visto una configuración de cuadrados u otra.

Sus conclusiones son que la visión activa hace al robot capaz de hacer la tarea con unos mínimos recursos en comparación con los clásicos métodos usados en visión artificial, consistentes en tomar una imagen completa y detallada y aplicar procesos que resaltan características como los bordes y zonas que superan un umbral determinado. Plantea que el sistema tiene cierto parecido con el movimiento sacádico del ojo (*saccadic*, *saccades*) en el que va moviéndose abrupta y rápidamente de un punto a otro del campo de visión. Estas *sacadas* buscarían en la imagen ciertos cambios que indicarían la presencia de una característica.

En resumen, su sistema explota las relaciones espacio-temporales entre las características del entorno durante la actividad del robot con una estructura más sencilla de lo habitual.

3.3.4. Inman Harvey, Phil Husbands, Dave Cliff y Nick Jakobi

Es interesante la visión interdisciplinaria de este grupo de la *School of Cognitive and Computing Sciences (COGS)*, *University of Sussex*, en el que se incluyen filósofos, biólogos e informáticos. Ello les ha permitido aproximarse al problema de la especiación y de la evolución no como un método de optimización, como se entienden los algoritmos genéticos en su concepción clásica, sino como un sistema de adaptación *filogenética* a un entorno cambiante. Por tanto, la evolución en SAGA (su sistema evolutivo) siempre es con una población convergida, “optimizada” en el sentido clásico de los algoritmos genéticos.

Usan la mutación como su fuerza evolutiva principal, divergente, y el cruce genético como estabilizador de la población. Basan el funcionamiento del algoritmo genético en el índice de mutación, proporcional a la longitud de la cadena genotípica.

La red neuronal que usan es recurrente y dinámica, de forma que usa los retardos de tiempo en las conexiones como un tipo de codificación de la información que procesan.

SAGA y todo el planteamiento desde el que desarrollan su trabajo está perfectamente explicado y evaluado en la tesis de Inman Harvey (Harvey, 1995). En esta tesis se plantea el grave problema de la sobreconvergencia de los Algoritmos Genéticos (Harvey, 1995). Debido a este conocido problema de sobreconvergencia, los robots aprenden *demasiado* y se pierde toda la variabilidad en la población. Como consecuencia se hace imposible la mejora de comportamientos y los individuos pierden la capacidad de generalizar y reconocer más información que la aprendida.

3.3.5. Adrian Thompson, Phil Husbands e Inman Harvey

Este grupo aborda el novedoso tema del Hardware Evolutivo, una variante de la Robótica Evolutiva, en la que se evolucionan, por simulación o físicamente, circuitos electrónicos que, posteriormente, se pueden usar como sistemas de control de un robot en hardware. Se intenta evitar las fuertes restricciones de modularidad y uso de señal de reloj para que el diseñador de los circuitos integrados no pierda el control sobre los efectos de cada parte del diseño. Asimismo, los problemas físicos del hardware (por ejemplo calor o variaciones del suministro eléctrico) hacen que el hardware se comporte de forma distinta. Todo esto se intenta solucionar mediante la evolución y

la medición de la adecuación del circuito en distintas fases de funcionamiento y variando el “entorno” (calor, voltaje...), tarea que comporta muchas dificultades.

Esta técnica evita la difícil descomposición del problema en módulos independientes y manejables, sobre todo si el problema tiene características no lineales y se prefieren aprovechar las propiedades no lineales del hardware.

Este grupo es el precursor de esta técnica aplicada a la Robótica. Han desarrollado un robot con dos sónares, y han llamado Máquina de Estados Dinámica (DSM) al controlador desarrollado por estas técnicas, por haber eliminado la sincronización en las señales. Con un algoritmo genético típico han obtenido este controlador, que permite al robot permanecer alejado de las paredes.

3.3.6. Stefano Nolfi y Domenico Parisi

Algunos de sus trabajos más importantes son (Nolfi y Parisi, 1993) (Nolfi et al., 1994) (Nolfi y Parisi, 1995). Nolfi y Parisi han desarrollado un sistema para evolucionar un controlador que haga que un *Khepera*, con ciertos añadidos como pinzas y sensores adicionales, agarre un objeto que ha reconocido, y lo mueva afuera de cierta área. Una parte es un simulador muy preciso, con muestreos (*sampled data*) de cientos de mediciones realizadas con el robot en el entorno físico. Aparte de estas novedades, el sistema evolutivo es el habitual: red neuronal *Feed Forward* sin capas ocultas (capa de entrada de cinco neuronas y de salida con cuatro) y algoritmo genético que representa los pesos de las neuronas y una función de evaluación que premia cada paso que se da para realizar la tarea de coger el objeto y dejarlo fuera.

En este trabajo observan que decae el rendimiento de los controladores cuando se evalúan en un entorno físico. En un trabajo posterior con Miglino y Lund (Miglino et al., 1995) abordan el problema de las simulaciones (utilidad, precisión, coste, validez) con la misma aproximación de muestrear el mundo para hacer las simulaciones lo más precisas posible, añadir ruido y evitar el “síndrome del barranco” al pasar el controlador a un robot físico con estos métodos y con la continuación de la evolución en el robot físico. Las conclusiones a las que llegan son que hay que tener en cuenta las diferencias entre sensores a primera vista idénticos y las pequeñas diferencias entre los objetos físicos y los simulados. También que debe introducirse ruido en la simulación de forma que “acostumbre” al controlador a ciertas discrepancias entre simulación y realización (entorno físico). No se enfrentan a la discusión del complicado tema del diseño de la función de evaluación (la función de *fitness*). Afirman que, para ellos, la metodología correcta en la Robótica Evolutiva es el muestreo del robot de su entorno físico para introducirlo de esa manera en la simulación. No aclara qué ocurre si tenemos que instalar ese controlador en varios robots, cuyos sensores y efectores tienen pequeñas diferencias. Probablemente, la solución sería hacerles evolucionar durante algún tiempo para ajustarse, usando el algoritmo genético como sistema de ajuste fino.

3.3.7. Randall Beer y Brian Yamauchi

Uno de los objetivos de Yamauchi y Beer, que comparten con el grupo de Robótica Evolutiva en Sussex, es obtener un enfoque biológicamente plausible. Para ello basta con repasar los trabajos de Beer (Beer y Gallagher, 1992; Beer, 1994; Yamauchi y Beer, 1994; Dellaert y Beer, 1995). Por ello Beer usa un tipo de red neuronal dinámica. Se diferencian principalmente en el tipo de algoritmo genético que emplean para la evolución, ya que el SAGA, desarrollado por Inman Harvey, tiene una concepción distinta de la evolución que el algoritmo genético típico que usan Beer y Yamauchi.

El sistema desarrollado en (Yamauchi y Beer, 1994) se compone de un conjunto de redes neuronales dinámicas que implementan comportamientos simples, combinadas mediante evolución. Las ventajas que proporcionan las

redes dinámicas permiten afrontar el problema de la obtención de *puntos de referencia* (*landmarks*) y la navegación a partir de estos. Posteriormente trasladaron los resultados a un robot Nomad 200 que, sin modificar el sistema de control, consiguió reconocer dichos puntos de referencia y su orden de aparición, base para un sistema de navegación. En el propio artículo remarcan la característica principal de su sistema: no sólo funciona en un entorno, sino que integra información en el tiempo para modificar su comportamiento futuro. Esto es precisamente predicción, planificación de acciones integrada en el funcionamiento de la red neuronal, sin necesidad de un algoritmo que implemente una planificación descendente de diseño humano, como es el caso de las fases sentir-modelar-planear-actuar.

3.3.8. Applied AI Systems, Inc. (AAI), Ottawa, Canadá

Esta empresa I+D ha trabajado en trasladar sistemas de laboratorio a sistemas de aplicación inmediata. En el campo de la Robótica Evolutiva, analizando lo ya existente (Gomi y Griffith, 1996), han extendido los trabajos de Floreano y Mondada a un entorno más complejo. El laberinto representa un típico plano de un edificio de oficinas. La tarea consiste en recorrer todas las dependencias repartiendo correo. La evolución se realiza al introducir las señales *bueno* y *malo* a través de sendos botones, durante el recorrido. Dichas señales modifican el valor de adecuación del controlador que en ese momento está al mando del robot. Todo el sistema evolutivo está integrado en las 250 Kb del Khepera. Continúan avanzando en el sistema para perfeccionar comportamientos de movimiento en el laberinto.

3.3.9. Henrik Hautop Lund, Barbara Webb y John Hallam

El problema estudiado por este grupo es obtener el comportamiento de las hembras de grillo de encontrar a los machos a través del ruido que producen.

Para desarrollar esta tarea el robot implementa un mecanismo que es consistente con la evidencia [neuroetológica](#), pero mucho más simple que los propuestos por los neuroetólogos para dicho comportamiento causado por la estructura neuronal y sensora. En concreto, el reconocimiento de la canción de los grillos macho ocurre como efecto colateral del dispositivo de localización, sin necesidad de procesamiento específico.

El controlador y hardware desarrollado para el Khepera (Lund et al., 1997) se ha probado con éxito con el sonido directo de verdaderos grillos de la especie *Gryllus bimaculatus*. El robot no se deja engañar por sonidos parecidos (continuos, o portadoras muy distintas de los 4.7kHz, en el caso de esta especie).

En general, su objetivo es usar un robot para verificar una hipótesis con datos biológicos poniéndolo en las mismas condiciones que el animal y obteniendo el mismo comportamiento. De esta forma validan las teorías [neuroetológicas](#) planteadas en otros estudios. Que se obtenga el comportamiento no quiere decir que el ser vivo tenga la misma estructura y mecanismos que la implementada en el robot, ya que eso sólo lo puede afirmar un estudio neurofisiológico, pero sí que es una posibilidad y permite reformular teorías en base a pruebas computacionales.

3.3.10. Trabajo en castellano

Aunque no se citan en el trabajo de Matarić y Cliff (1996) por ser más reciente, hay que resaltar el trabajo de dos grupos que han publicado en castellano en el campo de la Robótica Evolutiva: Ricardo A. Téllez, del grupo GREC² y sobre todo el grupo formado principalmente por Richard J. Duro, José Santos Reyes y José Antonio

²Grup de Recerca en Enginyeria del Coneixement, <http://www.upc.edu/web/grec/>

Becerra de la Universidade da Coruña³. Este grupo gallego orienta sus trabajos con la metodología de Robótica Evolutiva siempre a robots reales y aunque los controladores se obtienen en simulación, estudia su *traslado* al robot real, usando para ello diferentes tipos de ruido en la simulación. Plantean el uso de diferentes controladores neuronales, desde simples perceptrones a redes que incorporan retardos sinápticos en las conexiones para tareas que requieran algún tipo de procesado temporal de la información (Becerra et al., 2005).

3.4. Redes Neuronales

Las redes neuronales son sistemas computacionales que se basan en una estructura conexionista y totalmente paralela (salvo que habitualmente son *simuladas* en un ordenador clásico con arquitectura von Neumann) inspirada en los sistemas nerviosos naturales. La estructura de la red neuronal es un grafo, dirigido o no, con o sin ciclos, cuyos nodos se denominan *neuronas artificiales*. Éstas realizan una suma ponderada (con valores llamados *pesos* que multiplican cada conexión entre neuronas o *axón*) de las salidas de ciertas neuronas, que si sobrepasa un cierto valor o *umbral*, produce que la neurona dispare su salida (Maass, 1997).

En el mundo de las redes neuronales hay gran variedad de diseños, sin que se imponga ninguno. En algunos modelos la salida de la neurona es proporcional a la suma menos el umbral, y en otros la manipulación de la salida corresponde a una función *sigmoidea*, como la que corresponde a la fórmula 3.5.

Las redes neuronales más antiguas se estructuran en capas (los antiguos perceptrones multicapa) y la activación se propaga en un solo sentido, por lo que se las denomina *feed-forward*. El diseñador elige tras estudiar el problema el número de capas, el número de neuronas de cada capa y el tipo y cantidad de conexiones entre capas (por ejemplo, todas con todas o por grupos). El punto fuerte de este tipo de redes es establecer un mapeo directo entre entrada y salida, aproximar una función entre puntos de dos espacios n -dimensionales. Sin embargo, cada vez se encuentran más redes neuronales recurrentes (con ciclos) en las que puede haber o no estructura de capas. La forma en que la información fluye por los ciclos de la redes neuronales le proporciona un tipo de tratamiento temporal de la información. Las primeras solamente conectaban la salida a las neuronas de entrada, pero actualmente se usan las llamadas *fully-recurrent*, que se pueden definir como un grafo dirigido sin restricciones de conectividad.

Lo habitual es que la actualización de las neuronas sea síncrona, que es lo apropiado cuando la tarea de la red neuronal es el reconocimiento y clasificación de patrones, pero últimamente se está estudiando las redes neuronales que usan el tiempo como uno de los múltiples soportes de la información que procesan, ya que una de las características que se deben extraer consiste en la relación temporal de otras características. Su funcionamiento es totalmente asíncrono, con unas conexiones interneuronales que producen retardos en las entradas de las neuronas. Hay otros modelos en los que las neuronas son planteadas como Sistemas Dinámicos continuos, y por tanto su comportamiento se describe con ecuaciones diferenciales (Beer, 1995), como se puede ver en las fórmulas del punto 3.4.2.

Otros tipos de red neuronal son las de tipo estadístico y de agrupamiento (*clustering*) como las *Self-Organizing Maps* (SOM, mapas autoorganizativos o redes de Kohonen (1982)), o las *Learning Vector Quantization* (LVQ). Estas redes distan demasiado de la inspiración biológica de un sistema nervioso en cuanto a funcionamiento, aunque no en cuanto a funcionalidad (diferentes en cuanto a forma, no en el fondo) y se separan del esquema de diseño de un individuo con un sistema nervioso artificial evolucionado en el marco de la Vida Artificial.

Las redes neuronales son capaces de *aprender* variando los pesos de las conexiones, lo que produce que realicen diferentes mapeos entre entrada y salida, o diferentes trayectorias en el espacio de estados determinado por el

³<http://www.dc.fi.udc.es/ai/~santos/>

valor de activación de cada neurona. Estos mapeos y trayectorias son la base que les permite realizar labores de reconocimiento y clasificación de patrones. Hay dos formas de hacer que aprenda una red neuronal: *presentándole patrones* de entrada y salida, o sólo de entrada y suministrando una *señal de supervisión* positiva o negativa. Después de cada patrón se modifican los pesos para que se acerque a la respuesta correcta con esos patrones. Sistemas de aprendizaje más modernos varían la estructura de la red neuronal una vez determinada para un cierto individuo (en tiempo *ontogenético*).

Una de las características principales de las redes neuronales es su resistencia al ruido, es decir, a la imprecisión de los datos de entrada, que no consiguen perturbar su comportamiento, y da la respuesta adecuada. Otra característica muy importante es que las redes neuronales son capaces de responder correctamente ante entradas no presentadas durante la fase de entrenamiento, es decir, *improvisan*. Dicho de otra forma, las redes neuronales tienen distintas capacidades de interpolación (según sea su estructura) para producir una salida también interpolada, o la correspondiente a la más cercana a la entrada dada. Se realiza un intenso trabajo en el campo de la *Psicoacústica* que observa la actividad cerebral cuando se oyen sonidos que se corresponden a fonemas o que no está claro a qué fonema corresponde. En este último caso se activan zonas cerebrales que actúan cuando se oyen sonidos no relacionados con nuestro sistema de comunicación oral. Sin embargo, tanto con sonido (*fonos*) que corresponden a fonemas como si se trata de un músico que oye notas musicales⁴, se activan zonas cerebrales que indican que se está produciendo una categorización de los sonidos, una clasificación que relaciona cada sonido con un símbolo que emerge en nuestro cerebro, es decir, una representación interna (Liebenthal et al., 2005).

Lo mismo ocurre en robots: muchas veces ocurre que el robot sufre un sobreentrenamiento, y no es capaz de generalizar o interpolar (Mataric y Cliff, 1996). Esto es debido a un entorno demasiado simple, con lo que la red neuronal lo aprende demasiado bien. Este aspecto técnico de exceso de convergencia de la red conlleva a plantearse la complejidad del entorno.

3.4.1. Descripción matemática de las Redes Neuronales

Las redes neuronales más usadas en Robótica Evolutiva tienen un funcionamiento que se puede resumir en unas cuantas expresiones matemáticas que describen el comportamiento de cada una de las neuronas de la red. En primer lugar, su actualización síncrona. Se actualiza a cada vuelta del ciclo la salida a_i^t de la neurona i en el instante t en función del valor suma s de esa neurona en ese instante:

$$a_i^t = f(s_i^{t-1}) \quad (3.1)$$

$$s_i^{t-1} = \sum_{j=1}^N w_{ij} a_j^{t-1} + \theta_i \quad (3.2)$$

El valor s es la suma ponderada (con los pesos sinápticos w) de las salidas a de las neuronas en el instante $t-1$. A esta suma se le suma el valor θ_i , umbral de activación de la neurona i (*bias*). Estas fórmulas incluso describen las redes de McCulloch y Pitts (1943), si ponemos los pesos a 1, el umbral a 0 y los estados a -1 y +1.

La función aplicada al valor s puede ser:

⁴“Trained musicians can categorize musical intervals that musically untrained listeners do not perceive categorically” (Burns y Ward, 1978)

$$f(s) = \begin{cases} 0, & \text{si } s < 0 \\ 1, & \text{si } s \geq 0 \end{cases} \quad \text{umbral} \quad (3.3)$$

$$f(s) = \begin{cases} 0, & \text{si } s \leq -1 \\ s, & \text{si } -1 < s < 1 \\ 1, & \text{si } s \geq 1 \end{cases} \quad \text{proporcional} \quad (3.4)$$

$$f(s) = \sigma(s) = \frac{1}{1 + e^{-\alpha s}} \quad \text{sigmoidea con pendiente } \alpha \quad (3.5)$$

La activación a se suele interpretar, en el caso de usar la función *sigmoidea*, como la frecuencia de activación media de esa neurona en el intervalo Δt de actualización.

3.4.2. Continuous Time Recurrent Neural Networks (CTRNN)

Las *Continuous Time Recurrent Neural Networks* (CTRNN) (Beer, 1995) son las redes que resultan de llevar Δt hacia cero en las redes *sigmoideas* anteriormente descritas. Su descripción matemática se puede ver en la fórmula 3.6. La función sigmoidea 3.7 se aplica al final de un paso o al principio del siguiente, lo que es equivalente. El valor de activación de una neurona sigmoidea se puede interpretar como una medida de frecuencia media de disparo de la neurona en un instante determinado, mientras que las de pulsos se representa cada uno de los pulsos.

$$\dot{y}_i = \frac{1}{\tau_i} \cdot \left(-y_i + \sum_{j=1}^N w_{ji} \cdot \sigma(y_j + \theta_j) + I_i \right) \quad i = 1, 2, \dots, N \quad (3.6)$$

$$\text{siendo } \sigma \text{ la función sigmoidea} \quad \sigma(x) = \frac{1}{1 + e^x} \quad (3.7)$$

Como nuevos valores I_i representa una entrada externa y τ hace que cada una de las neuronas dependa del tiempo, ya que con diferentes valores la caída del nivel de activación de la neurona es rápida o lenta, al igual que la subida en el nivel de activación. La velocidad de actualización de la red neuronal debe ser notablemente mayor (el intervalo entre dos actualizaciones será menor) que el valor de τ para no obtener comportamientos no deseados.

La consecuencia de esta representación del tiempo en la estructura de la CTRNN es crucial, porque:

- permite por una parte una forma de memoria a corto plazo
- es posible el procesamiento del tiempo en general
- se puede demostrar que una CTRNN aproxima cualquier sistema dinámico bajo ciertas condiciones (Funahashi y Nakamura, 1993; Beer, 1995)
- debido al punto anterior, se abre una visión de la red neuronal como sistema dinámico parcialmente acoplado a los sensores y al entorno

3.4.3. Redes Neuronales de Pulsos

En inglés se conocen bajo varios nombres, *Pulsed Neural Networks*, *Pulse Code Neural Networks* (PCNN) y *Spiking Neural Networks*. La base de esta familia de modelos de red neuronal es la simulación en el tiempo del

comportamiento de una neurona natural típica, que acumula potencial eléctrico y se dispara, para pasar por un momento a un estado refractario y volver a la estabilidad. Este ciclo se denomina potencial de acción, pulso, o “chispa” (*spike*) (Maass, 1999). En este libro se describen los usos más habituales de este tipo de redes. En otro artículo de 1997, Maass remarca que *se han acumulado evidencias experimentales de que los sistemas neuronales biológicos usan las características temporales de los potenciales de acción para codificar información*. Además, resalta que aunque el análisis teórico de las redes neuronales de pulsos no es nuevo en la *Neurobiología*, *Biofísica* y *Física Teórica*, sí que faltaba un *análisis riguroso de su capacidad computacional*. Tienen una gran variedad de comportamientos, incluyendo dinámicas caóticas (Beer, 1995).

Se pueden indicar varias ventajas de estas redes. Son biológicamente plausibles (Floreano et al., 2006), y por lo tanto nos acercan a las *Neurociencias*. Integran percepciones en el tiempo (Yamauchi y Beer, 1994) con lo que se obtienen las mismas ventajas que las CTRNN. Las redes neuronales de pulsos procesan información temporal con los retardos en los axones y permiten el reconocimiento de patrones temporales (y por tanto la extracción de características temporales) (Di Paolo, 2003a), como indica Maass (1997), son más resistentes al ruido (su activación es digital), equivalentes a las *sigmoideas* y muchas veces con menos neuronas. Todo ello es debido a que son redes neuronales que incorporan una dimensión temporal en su comportamiento, ya que por sí mismas tienen una dinámica propia de la que carecen por ejemplo las CTRNN. Por ello pueden desligarse del entorno y ser un sistema dinámico autónomo. Esta característica puede llevar a un mecanismo de generación de respuestas a partir de una entrada desde el entorno.




Figura 3.3: Pulso generado a partir de la fórmula 3.8, con el que se simula burdamente el disparo de una neurona. A los tres primeros valores se les asigna el valor 0. Los valores son $\alpha = 1,666$ $\beta = 2,5\pi$ y $t = 0'1 \cdot \text{paso}/32$ s.

Izhikevich (1998) apunta a que los sistemas basados en osciladores tienen muy diferente comportamiento bajo ciertas condiciones (entre ellas, la red está débilmente conectada) si hay retardos en las conexiones (*axon time delays*). En 2006, Izhikevich arguye que es una gran ventaja la dimensionalidad infinita de las redes de pulsos con retardos axonales por su capacidad de información sin precedentes y por los patrones de disparo estables que son imposibles sin los retardos. Este autor define unas Redes Neuronales de Pulsos cuyas neuronas están definidas como Sistemas Dinámicos.

El uso de las redes neuronales de pulsos ha sido inicialmente en *Neurociencias* y sistemas de visión artificial, pero se han empezado a incluir en modelos de Robótica Evolutiva sólo recientemente (Di Paolo, 2003a; Maass, 1997; Floreano y Mattiussi, 2001).

La dinámica de la activación neuronal se puede expresar como una función del tiempo que empieza cuando la suma ponderada de las activaciones sinápticas sobrepasan el umbral. Tiene una parte de atenuación exponencial y otra parte de oscilación que permite un periodo refractario, como se puede ver en la figura 3.3 y en la fórmula 3.8, donde a_t es la descripción del pulso, t es el tiempo, y α y β son coeficientes positivos.

$$a_t = e^{-\alpha t} \cdot \cos(\beta t) \quad (3.8)$$

Di Paolo (2003a) afirma que en la mayor parte de modelos en [Neurociencia Computacional](#) hace abstracciones y modelos de pruebas de pocas neuronas con entradas aleatorias, y a menudo adolecen de una visión de agente o individuo como un todo.

3.5. Algoritmos Genéticos

Los algoritmos genéticos fueron impulsados definitivamente por John Holland (1975). Se encuadran en los algoritmos evolutivos y estos en la computación evolutiva, aunque estas distinciones son difusas, como veremos más adelante.

Son una técnica de optimización o búsqueda en un espacio de estados multidimensional, cuya mayor utilidad se demuestra en problemas en los que la solución es el resultado de un proceso no lineal, aplicado a un conjunto de parámetros que definen dicho espacio de estados multidimensional (Goldberg, 1989). Dicho conjunto de parámetros definen una posible solución al problema, y son un punto en el espacio de estados, denominado también *genotipo*. En este tipo de problemas es imposible aislar las variables para obtener su valor óptimo por separado. Por ello, el método que siguen los algoritmos genéticos es el más efectivo.

Tenemos un conjunto de posibles soluciones al problema (puntos en el espacio de estados), que denominamos *población*. Asignamos a cada elemento de la población (*individuo*) un valor relativo que mide lo que se acerca a la solución óptima, según la expresión de su genotipo, es decir, según su *fenotipo*. Este valor se denomina *de adecuación* o “*fitness*”, y se calcula con una función del mismo nombre. Si el espacio de estados es de dimensión n , el “paisaje de adecuación” (*fitness landscape*) es un conjunto de puntos en un espacio de $n + 1$ dimensiones, que puede ser continuo y formar una superficie (como un paisaje), o ser rugoso o completamente inconexo, lo que influye en la capacidad de búsqueda en el algoritmo genético. De entre todas las soluciones posibles se escogen, en función de su adecuación, las mejores y se genera la *descendencia*, que sustituye a los individuos no elegidos o a todos los de la población anterior. Se puede mantener una *élite* de individuos que pasa a la siguiente generación sin modificaciones. La descendencia se obtiene a partir de procesos de mutación y *cruce* o recombinación de los parámetros que definen cada individuo: a partir de dos producimos con el cruce uno o dos conjuntos de parámetros, mezclando los valores según un proceso aleatorio o fijo (independiente de lo que signifiquen los parámetros). Además, se introduce otra cantidad de aleatoriedad con la mutación, que consiste en variar un cierto valor al azar. Cuando la función de adecuación nos indica que una solución es óptima, o subóptima, se puede detener el proceso.

El algoritmo es totalmente adaptable al problema que deseamos solucionar. Se pueden variar los métodos de selección, emparejamiento, cruce, mutación, generación de la población inicial y otros específicos del problema. Debido a su flexibilidad también produce problemas de ajuste de parámetros, como la presión selectiva que lleva a máximos locales de los que el algoritmo no sale, y el fenómeno contrario, que consiste en que el algoritmo no descarta *esquemas* que no producen ventaja evolutiva. El Teorema de los Esquemas (Goldberg, 1989) demuestra (bajo ciertas condiciones) que los esquemas (subconjuntos de los parámetros) que aporten un aumento en el valor de adecuación se irán seleccionando y su número se multiplicará exponencialmente hasta predominar en la

población. Es decir, que el algoritmo mejora la población hacia soluciones óptimas.

El concepto de esquema se basa en un patrón en el que *encajan* parte de los individuos de una población que se evoluciona mediante algoritmos genéticos (Holland, 1975). El teorema prueba que los esquemas que contribuyen más que los demás a que un individuo obtenga mejor valor de adecuación *percolan*, se extienden por toda la población (como se extendió como el fuego entre los Fórmula 1 el diseño de Cooper que colocaba el motor en posición trasera⁵). El caso contrario es que los que menos aportan, desaparecen. El problema es que para que funcionen el cruce y la mutación los esquemas deben destruirse, por lo que se duda de la validez en el transcurso de las iteraciones (Holland, 1975; Goldberg, 1989; Vose et al., 2003).

Si usamos estrictamente las definiciones, denominamos Algoritmos Genéticos a los algoritmos evolutivos en los que la información se codifica en una tira de ceros y unos de tamaño fijo, y según el lugar que ocupan los dígitos binarios, tienen un significado concreto, por ejemplo, son la codificación en complemento a dos del peso de la conexión entre dos neuronas determinadas, que siempre existen. Este tipo de codificación es muy incómodo a la hora de evolucionar estructuras de tamaño variable, por lo difícil que resulta codificar información variable en estructuras de tamaño fijo. Además porque el cruce genético entre dos tiras de este tipo es habitualmente una operación destructiva de la información, y por ello equivale a una tasa de mutación insoportable. Debido a esto, Harvey (1995) apoya el proceso de su algoritmo genético SAGA en la mutación controlada de los individuos de su población, en los que su codificación genética es de longitud variable. La población es homogénea y evoluciona sólo a través de la mutación. La codificación tiene su significado por la posición en la secuencia.

Si codificamos programas, por ejemplo en LISP, se denomina Programación Genética (Koza, 1992). Si son números reales, se suele llamar Estrategias Evolutivas. También hay variantes que se usan en sistemas expertos y otros que usan reglas. De todas formas, y como ya se había indicado, hay distintas maneras de clasificar estas técnicas (ver el capítulo 1 del libro de Wang et al. (2006)).

3.6. Algoritmos Genéticos con Redes Neuronales en la Robótica Evolutiva

Anteriormente ha quedado suficientemente discutido que la Robótica Evolutiva se basa en aplicar técnicas evolutivas con el fin de obtener el controlador de un robot, y opcionalmente, su forma física, ya que el diseño a mano es casi imposible (Salomon, 1997). Para ello se debe escoger una de las técnicas evolutivas buscando la mejor adaptación al tipo de controlador. Por ejemplo, si se busca optimizar parámetros de un dispositivo analógico, podría ser interesante usar números reales en la representación de la información genética, y no codificarlos en binario, como es lo habitual. De la misma forma, la mutación no sería un cambio al azar de bits, sino sumar un número generado aleatoriamente con una función de probabilidad normal (gaussiana). No existe ninguna regla que indique que una elección es mejor que otra, a excepción quizás del Teorema de Esquemas, siempre que nos encontremos dentro de unas estrictas restricciones de validez del teorema.

La elección del tipo de controlador es también cuestión de gustos e intuición. Existe una idea compartida por grupos de investigadores sobre la utilidad de ciertos controladores para determinadas tareas, pero está asumido sin ningún tipo de teoría bien fundamentada. De hecho, es dudoso que se pueda crear una teoría que, prescindiendo de la experimentación, pueda afirmar que un tipo de Redes Neuronales es mejor que otro para determinado problema. Se puede decir que el uso de las Redes Neuronales en la Robótica Evolutiva es predominante, y es debido a las ventajas que ofrecen, y a las dificultades que se presentan al usar evolución sobre Sistemas Expertos, programas LISP o Arquitecturas de Subsunción. Las ventajas principales son su resistencia al ruido, el paralelismo, su capacidad para modelar sistemas dinámicos en el caso de las redes neuronales recurrentes y dinámicas, y la buena respues-

⁵http://en.wikipedia.org/wiki/Cooper_Car_Company#Rear-Engined_Revolution

ta a su evolución mediante Algoritmos Genéticos, por ser ambos mecanismos sintácticos de los que “emerge” el significado de sus acciones. Hay dos formas de usar conjuntamente algoritmos genéticos y redes neuronales:

- usar un algoritmo genético como optimizador de posibles soluciones en un espacio de estados, y por ejemplo buscar el conjunto de pesos de la red neuronal en vez de usar un algoritmo como el *Backpropagation* (retropropagación del error), o también buscar el número de neuronas de cada capa que mejor se ajuste a una función continua y derivable (sobre esto existen teoremas que establecen unos máximos, aunque muy altos, y también con unas condiciones muy estrictas).
- plantear la evolución de Redes Neuronales mediante Algoritmos Genéticos como una evolución no optimizadora, en la que el único objetivo es satisfacer ciertas restricciones.

Se elige entre estas dos visiones según la visión que se tenga de la Robótica Evolutiva, más técnica o más inspirada en la Biología, y según las posibilidades que se tengan en ese momento, como puede ser la complejidad de la simulación. Lo que está claro es que, conforme el problema se torna más realista, la visión optimizadora del algoritmo genético se diluye, porque es imposible analizar cuán buena es una posible solución fuera del cumplimiento de las restricciones del sistema y de ciertas condiciones de la función de adecuación.

3.7. La navegación en la Robótica Evolutiva

En esta sección se analizan las características que hay que tener en cuenta al hablar de navegación en la Robótica Autónoma, y por tanto en la evolutiva.

Una buena introducción al tema de la navegación en la Robótica Evolutiva se encuentra en el primer capítulo del libro de Wang et al. (2006).

La navegación de robots autónomos se trata en el capítulo 5 de la tesis de Lazkano Ortega (2004). En primer lugar se trata la navegación simbólica, en la que se modela el entorno y se generan mapas por el robot o le son suministrados. El mapa puede ser a escala (métrico) o no (topológico). Se calcula la posición del robot a través de medidas absolutas como por satélite con el sistema GPS (Global Positioning System) o relativas como la odometría (trayectoria recorrida desde una posición conocida), o las mediciones de los sensores sobre el entorno. Puede ser necesario el movimiento del robot para eliminar la duda ante entornos similares. En base a ese mapa se planifica la trayectoria, en un planteamiento propio de la Inteligencia Artificial clásica (ver las secciones 2.8 y 2.9.1).

En segundo lugar se presenta la “navegación de inspiración biológica”, en la que no hay ni mapas ni la colocación en el mismo. Sólo se navega a través del reconocimiento de marcas (puntos de referencia) y por *taxias*, además del movimiento aleatorio o *browniano*. La composición de estos movimientos locales produce una navegación que permite alcanzar un objetivo que no era perceptible desde el punto de inicio. La sucesión de movimientos locales se puede llevar a cabo con la respuesta activada por la percepción (al detectar la llegada a un punto se comienza el movimiento hacia el siguiente).

Se puede definir marca a cualquier activación sensorial diferenciable a otras. Pueden ser elementos habituales en el entorno (una luz o una esquina) o estar colocados para que lo use el robot (un código de barras). Pueden ser locales (lectura de sensores de distancia) o globales (GPS, posición del sol o brújula). Pueden ser estáticas o dinámicas, ya que la distancia entre paredes de un pasillo se mantiene aunque el robot esté moviéndose, pero la forma de una luz no.

Como último punto del capítulo 5 de la tesis de Lazkano Ortega se presentan dos ejemplos de sistemas de navegación basados en comportamiento: *Polly* y *Toto*.

El trabajo presentado en la tesis de Lazkano Ortega está encuadrado en un planteamiento *híbrido* entre el esquema deliberativo y el reactivo, dentro de lo definido en la sección 1.1 (Arkin, 1998). Aun intentando introducir las características de los planteamientos reactivos, cualquier sistema que no sea estrictamente reactivo adolece del excesivo control por parte del ingeniero, que debe conocer exhaustivamente el hardware y analizar el *punto de vista del robot* con el fin de diseñarlo de forma que se adapte a su cuerpo y a su entorno.

La Robótica Evolutiva hace ese trabajo dejando en manos de las estrategias evolutivas la **emergencia** de los mejores diseños (Wang et al., 2006). Los puntos de referencia los elige el robot y la forma de manejar la información (posicionamiento, taxias, navegación en general) es producto de la evolución, y probablemente difícil de analizar.

No hay trabajos en Robótica Evolutiva que obtengan comportamientos de navegación más complicados que una taxia o el reconocimiento de una característica simple y el movimiento hacia ella (Harvey et al., 1994; Lund et al., 1997), excepto el de Suzuki (2007), que se analiza en el apartado 3.3.3. Introducir señales complejas es el primer paso hacia una verdadera navegación a través de la Robótica Evolutiva.

La gran ventaja de la Robótica Evolutiva es que se podrá llegar a comportamientos mucho más complejos salvando el problema de la escalabilidad, que se describe más adelante en este capítulo.

3.8. Objetivos de los modelos en la Robótica Evolutiva

En el trabajo de Barandiaran y Moreno (2006) se plantea una clasificación de los trabajos en Vida Artificial, y por ello aplicable a la Robótica Evolutiva. En base a tres objetivos (estético, **epistémico** y técnico) se crean cuatro categorías no estancas que se describen a continuación y con las que se puede relacionar cada trabajo.

Modelos genéricos: modelos que estudian el funcionamiento, la dinámica de una estructura sintáctica como las CTRNN, los autómatas celulares o las redes booleanas.

Modelos mecanicistas: modelos que representan lo más fielmente posible cada una de los elementos del objeto modelado.

Modelos funcionales: modelos que, a falta de conocer el funcionamiento interno del objeto modelado, plantea una posible estructura de interacción entre módulos con el fin de obtener el comportamiento del objeto modelado y validar esa estructura como una teoría sobre el funcionamiento.

Modelos conceptuales: modelos que permiten estudiar relaciones entre conceptos que se usan en una teoría. Como ejemplo se pueden indicar los trabajos para estudiar la relación entre aprendizaje y evolución y el efecto Baldwin.

El presente trabajo de Robótica Evolutiva podría clasificarse sobre todo como modelo funcional, y en parte como mecanicista. Sus objetivos principal sería técnico (*engineering goals*) y el secundario **epistémico**, por ser un modelo funcional.

3.9. Simulaciones y realizaciones en Robótica Evolutiva

En el terreno de la Robótica Evolutiva hay tres corrientes principales, dependiendo del grado de simulación y realización que contengan. Se pueden plantear trabajos únicamente en simulación, otros en los que se comprueban los resultados en un robot real, y los que directamente llevan a cabo la evolución en robots reales.

3.9.1. Sólo simulación

Se simulan las capacidades motrices de un individuo, el robot, en su entorno físico inmediato. Esto es debido a la característica de agente de cualquier robot, es decir, un mecanismo que modifica su entorno, incluyendo su propio movimiento. Aunque existe divergencia en cuanto a la terminología, podemos considerar por esto que existen trabajos de simulación pura en Robótica como el de (Sims, 1994), en el que el objetivo no es obtener un robot corpóreo que funcione en un entorno físico real. En (Cliff et al., 1993) se diseña un robot virtual que es capaz de dirigirse al centro de su entorno utilizando exclusivamente la información proporcionada por sus sensores también virtuales.

3.9.2. Simulación y comprobación de los resultados en robot real

Aquí se pueden clasificar grupos de trabajo como el Grupo de Robótica Evolutiva de la *School of Cognitive and Computing Sciences* (COGS) en la Universidad de Sussex (Husbands et al., 1997; Harvey et al., 1997). Este grupo utiliza la simulación lo menos posible, y la usa como herramienta que permite evitar y simplificar los problemas que lleva la evolución sobre robots reales. Una de sus ventajas es la gran cantidad de tiempo que se ahorra si la simulación es sencilla, o si el robot carece de potencia computacional. Dentro de esta corriente existen dos maneras de diseñar la simulación, en función del origen de los datos que se suministran al robot simulado. En la primera se muestrea la señal real que puede recibir el robot y se introduce en la simulación, mientras que en la otra se desarrolla un sistema para generar la señal.

Un ejemplo de implementación de los muestreos en la simulación es el trabajo de Miglino et al. (1995), que realiza una descripción detallada de la metodología que consideran necesaria los autores para evolucionar robots en simulación que directamente funcionen en el robot real. Muestran la validez de su metodología, muestreando datos del entorno a través del propio robot *Khepera*⁶, y construyendo a través de ellos la simulación, incluyéndolos como tablas que consulta el entorno programado, con el fin de “alimentar” los sensores del *Khepera* virtual. Con esto consiguen que el robot produzca el mismo comportamiento de forma tan eficiente en simulación como en realización. Si la eficiencia baja al trasladar al robot desde la simulación basta con unas cuantas generaciones más en el algoritmo genético. Si la situación lo requiere introducen una forma de ruido “conservativa”.

Por otro lado está la implementación de un modelo matemático idealizado como simulación, como el realizado en un muy interesante trabajo del grupo de COGS. En el mismo, Jakobi, Husbands y Harvey (1995) estudian las condiciones que impone el uso de simulaciones en la Robótica Evolutiva, y para ello implementa una simulación a partir de un modelo matemático idealizado, que resulta del análisis de la física en la que funciona el robot, su entorno y la propia del *Khepera*. Las constantes y coeficientes del modelo fueron extraídos de mediciones y muestreos a través del robot real, pero esos datos sólo son usados para obtener dichos valores de las ecuaciones, es decir, los muestreos no son introducidos en el modelo como en el caso anterior.

3.9.3. Evolución exclusivamente en robots reales

Un buen ejemplo de esta corriente es (Floreano y Mondada, 1996), que efectúa la evolución conectando un robot *Khepera* a una estación de trabajo. En ésta ejecuta el algoritmo genético y los sistemas que usa para controlar el robot dentro del entorno que le preparan, además de la propia red neuronal *feed-forward* que controla al *Khepera* que evalúa en cada momento. En el robot se tratan los datos de los sensores y las órdenes para los motores, así

⁶En estos mismos trabajos (Miglino et al., 1995) y en otros (K-Team, 1993; Jakobi, 1998) se puede consultar una descripción completa del robot. En general se puede destacar que son pequeños, con poca inercia, dos ruedas laterales y ocho sensores infrarrojos, con posibilidad de añadir múltiples tipos de sensores, como hacen Lund et al. (1997)

como un láser usado como posicionador absoluto del robot para que el algoritmo genético coloque al robot en el lugar necesario para comenzar la prueba y para que obtenga los datos precisos con los que se evalúan las acciones del robot.

3.9.4. Conclusiones

Si bien las corrientes de más peso de la Robótica Evolutiva que usan simulación comparten la idea de representación de la física del sistema y la técnica de combinar Algoritmos Genéticos con Redes Neuronales, los resultados de los métodos son diferentes, así como sus dificultades. Queda aquí claro cómo el uso de un mismo robot *Khepera* puede tener orientaciones teóricas muy diferentes. Aparte de las ventajas de manejo de este sistema (pesa poco, es pequeño, permite la experimentación en una superficie reducida, es fácilmente transportable, etc.), el uso de *Khepera* se ha convertido en un estándar que permite comparar resultados.

3.10. Límites y problemas de la Robótica Evolutiva

En esta parte se especifican cuáles son los problemas que dificultan el avance de la Robótica Evolutiva hacia sus objetivos. Gran parte de ellos se analizan en una revisión del estado del arte de Mataric y Cliff (1996).

- Problemas en la evolución en robots reales
 - Tarda mucho más tiempo que en las simulaciones
 - Las baterías de los robots limitan el método
 - Los robots necesitan continuas reparaciones durante el proceso
- Problemas de las simulaciones
 - Los errores en el modelo del entorno y el ruido limitan la utilidad
 - La validez de las simulaciones está relacionada con su precisión, con lo que se vuelven costosas y específicas
- Problemas de evaluación y de diseño de la función de adecuación (fitness)
 - Diseño laborioso y artesanal, que produce fallos y errores semánticos
 - Coarta la libertad y potencia del algoritmo genético si es muy compleja
 - Hay grandes dificultades al medirla con evolución en robots reales
 - Repetibilidad experimental y efectos del indeterminismo
- Problemas de la evolución mixta y el “salto” (*gap*)

Desde que se publicó este análisis se han publicado trabajos que han hecho frente a estos inconvenientes. Los robots funcionan mejor y las baterías duran más. Las simulaciones se han hecho más lentas debido a la complejidad de los entornos. Jakobi (1998) en su tesis doctoral rebate los puntos de la utilidad y validez de las simulaciones por lo menos en parte, *para ciertos tipos de comportamientos y robots*, y señala como ejemplo la visión y el movimiento de un octópodo.

El análisis y evaluación de la posible obtención del comportamiento deseado es cualitativo, y basado en el juicio humano, y por tanto dificultoso. Como consecuencia, es muy difícil diseñar una función que indique cuán capaz es de llevar a cabo la tarea. Por ello, la función de adecuación muchas veces sólo indica de forma relativa

la capacidad de un individuo de hacer una tarea. Las tareas que se pueden obtener quedan restringidas a las que se puedan expresar mediante una función de adecuación para medir la habilidad.

En cuanto al “salto” o *gap* se podría pensar que la mejor solución es el punto medio, es decir, hacer una primera aproximación al problema mediante una simulación más sencilla, que nos ahorra trabajo que produce el robot real sobre todo en los primeros pasos de la evolución, y posteriormente afinar el resultado con el propio robot para ajustarse al ruido real, a la precisión que no tenía el modelo, etc. Pero este acercamiento incluye el problema del acoplamiento entre las técnicas ya que el resultado parcial del problema obtenido en la simulación puede no dar un resultado siquiera parecido al trasladarlo al robot real. Por ello, el proceso siguiente en el robot real no es una continuación, “no funciona el trasplante”. En este punto se basa la ya citada tesis de Jakobi (Jakobi, 1998), en la que argumenta que con un diseño adecuado de la simulación el controlador que se ha evolucionado puede funcionar correctamente tanto en simulación como en realidad. Para ello sienta unas normas necesarias para obtener una simulación *mínima* que refleje la parte del mundo llamada *conjunto base*, que se define como lo que puede afectar al comportamiento que se quiere desarrollar.

3.10.1. La morfogénesis: evolución de la forma del robot

La *morfogénesis* es el desarrollo del ser vivo, en otras palabras, el crecimiento. En los seres sexuados empieza en la fecundación e incluye las posibles metamorfosis, hasta obtener la forma final. Este problema de la morfogénesis es el principal y más difícil al que debemos enfrentarnos en el campo de la Robótica Evolutiva: la forma de los individuos que evolucionan debe estar descrita en la información genética, pero su expresión (la traducción de esas instrucciones en su estructura) debería ser no lineal para mejorar la capacidad evolutiva. Han sido múltiples los esfuerzos para desarrollar mecanismos adecuados (redes de Kauffman...) pero se encuentran en una fase de análisis teórico de las posibilidades. En modelos en los que se aborda un problema real, no de prueba, la información genética es habitualmente una copia aproximada de la forma final del individuo, y en la mayor parte de las veces esto se traduce en una matriz de pesos de la red neuronal. Jakobi (1998) por cuestiones prácticas no aconseja usar esquemas de codificación más biológicamente inspirados en el desarrollo natural.

Lo que se puede deducir de las aportaciones de Rodney Brooks (ver la subsección 2.9.1) es que la forma del robot es determinante en los procesos cognitivos del robot, ya que es el camino que proporciona la parte semántica a los símbolos y modifica el proceso de la percepción.

Una parte muy importante de la morfogénesis es el desarrollo de los sensores, y en menor medida, de los efectores (Harvey et al., 1994). Esto es debido a que la percepción depende del correcto acoplamiento entre el sensor (el órgano sensorial) y la red neuronal (el cerebro), de manera que se produzca una adaptación semiótica (Salthe, 1995). Esto ocurre de la misma forma que dos personas crean símbolos y un lenguaje cuando no tienen una lengua común y deben comunicarse. El resultado de la percepción depende de las relaciones obtenidas en el proceso morfogenético entre la señal, el sensor y la red neuronal. El significado de un valor en una parte del proceso perceptivo estará en función de la forma de percepción de anteriores fases, la misma estructura de los sentidos proporcionan significado a la percepción. La respuesta de los ojos de un daltónico a distintas (según nosotros) señales es la misma, por lo que para dos personas la misma percepción visual se corresponde a diferentes señales (“realidades”) según la capacidad visual del individuo. Peter Cariani (1989, 1992, 1998) incluye la necesidad de mecanismos que permitan durante la evolución la creación de nuevas primitivas, es decir, la *emergencia* de nuevos elementos atómicos que constituyen los ladrillos de las percepciones sensoriales.

Macinnes y Di Paolo (2006) citan a Brooks (1991a) para afirmar que es necesario que el robot tenga contacto directo con el mundo para poder decir que es corpóreo. Citan también a Bourguine y Varela (1992) con el fin de usar

la definición de autonomía para justificar que no se puede realizar un “preproceso” del mundo en los sensores.

Al hablar de percepción y de la extracción de información que se realiza al percibir a través de los sensores es necesario tener en cuenta la *Paradoja de Collier*. La Paradoja de Collier afirma que la cantidad de información compartida por los seres vivos y el entorno no es ni alta ni muy baja (Collier, 1986; Brooks, 1995; Brooks y Wiley, 1986). Así, cambios en el entorno no influyen en la estabilidad del individuo, de no ser extremos. De lo contrario, una sobre-adaptación (al compartir una alta cantidad de información) haría vulnerable al más mínimo cambio, y una infra-adaptación haría muy difícil la supervivencia a los individuos.

De esto deberíamos deducir que debemos tender a hacer simulaciones tales que la información del entorno sea alta, para que se pueda establecer la proporción adecuada entre un individuo complejo, su entorno complejo, y una cierta capacidad de información compartida. Con un entorno simple la información compartida sería muy baja, a no ser que la información del propio individuo fuera baja (de poca complejidad), con lo que su comportamiento sería simple. Se puede en cierta forma *complicar* un entorno para que no sea trivial la forma de funcionar de un robot, como hacen Suzuki y Floreano (2006), aunque claramente es insuficiente para llegar a obtener un verdadero robot autónomo, flexible ante entornos radicalmente variables.

3.10.2. El problema de la *escalabilidad*

“Escalabilidad” es un neologismo proveniente del verbo inglés *scale up* que se usa en informática para indicar la capacidad de un sistema (diseño, estructura, algoritmo. . .) de ser eficiente, de conservar sus propiedades, cuando trabaja con gran cantidad de datos, de nodos de red o de subestructuras replicadas.

Es el problema que empuja a enfrentarnos a la *morfogénesis*. Los algoritmos genéticos trabajan correctamente cuando los datos son pocos, el espacio de estados es pequeño y es aceptable una búsqueda. Cuando el espacio de estados es inmenso los algoritmos genéticos simplemente no funcionan, a no ser que la función de adecuación sea muy suave. Con suave se quiere expresar que el paisaje de adecuación (ver la sección 3.5) tienda a ser continuo y derivable. Cuando el paisaje es escarpado no hay forma de llegar a la *cumbre* (maximizar la función de adecuación) subiendo la mayor pendiente en corta distancia, mientras que sí es posible cuando es suave.

Podemos crear robots que hagan tareas simples y extrapolar el mecanismo para suponer que con esos métodos se pueden desarrollar ciertas tareas más *complejas*⁷, pero no es tan evidente. Jakobi (1998) indica este problema en el caso de las simulaciones mínimas que desarrolla en su tesis: “*Queda por verse si la aproximación de las simulaciones mínimas es escalable*”.

⁷El término “*complejidad*” implica un nuevo campo de discusión sobre cómo podemos medir cuán complicada es una tarea, y si la tarea es compleja en el significado usado en Sistemas Complejos.

Parte III

La aplicación TOPOS: diseño, ejecuciones y análisis de resultados

Descripción de la simulación Topos

A continuación vamos a describir el modelo TOPOS de una forma general, para poder abordar posteriormente con detenimiento cada módulo con una visión de conjunto previa.

4.1. Diseño general del modelo

El sistema desarrollado en este trabajo es un modelo computacional (o simulación, según los significados filosóficos que se dan a estas palabras). Este modelo denominado TOPOS¹ (González-Nalda y Cases, 2006a,b, 2008) se compone de una superficie llana y sin obstáculos, los faros (emisores de una señal) y los individuos (llamados *topos*). Los límites son cerrados, no permiten que los topos se alejen más allá ni es toroide, es decir, no aparecen por el lado contrario del mapa (muy habitual en los mundos artificiales). Para representar las proporciones, distancias y movimientos de forma más realista, usamos una medida llamada *metro*. Por *metro* se entiende la cantidad de mil unidades o puntos del mundo. Los ángulos se miden con una precisión de un grado sexagesimal. Los elementos no sufren *choques*, no *topan* unos con otros, es decir, se atraviesan como si fueran fantasmas. Esto es así porque no es necesario evitarlo para obtener los objetivos buscados en esta simulación, y supone una gran carga computacional.

En TOPOS se hace una generalización de la estructura de un vehículo de Braitenberg (ver sección 2.9.4) al usar una red neuronal formada por dos subredes simétricas parcialmente interconectadas (comparten 4 neuronas). Cada una de las dos subredes es una red de 8 neuronas de pulsos, es decir, redes neuronales recurrentes totalmente

¹El nombre está relacionado con la idea de navegación y movimiento con sonido: el *topo* es, en castellano, un animal que cava galerías y es prácticamente ciego. También, y con origen en el cumanagoto, una lengua amerindia, un topo es una medida de longitud de aproximadamente una legua y media, usada entre los indios de América Meridional. En euskara, *topo egin* significa chocarse, encontrarse. En griego, *topos* es lugar. El tren que va de Donostia a Hendaya es llamado popularmente “el topo”.

conectadas y de pulsos con retardos en los axones. La red tiene 12 neuronas en total y 12 sensores (cada uno conectado a una neurona, ya sea a la subred del mismo lado o al del otro).

TOPOS es un programa de ordenador (totalmente escrito en `java`) en el que se desarrolla una estructura de un sistema de Robótica Evolutiva típico, en el que encontramos una población de un cierto número de agentes o robots. Estos agentes son modelos idealizados de robots del tipo Khepera, con dos ruedas independientes (K-Team, 1993) cuyos parámetros se han obtenido de su genoma y que son evaluados en una tarea, seleccionados y cruzados los mejores para obtener una nueva generación.

El genoma es un vector o tabla unidimensional de números reales que determinan los valores de sensores (frecuencia, umbral y nivel de saturación, sensibilidad a frecuencias cercanas), neuronas, retardos en axones, pesos sinápticos y velocidad de los motores. El algoritmo genético y la selección mantienen una *élite* de los mejores topos de cada generación (25 %) y el resto de la población se genera por cruce de dos progenitores elegidos aleatoriamente de la población (excluyendo a los 25 % peores de la generación anterior).

Al lanzar la ejecución del algoritmo genético se define la tarea, que consiste en visitar uno de los dos puntos del plano desde el que se emite sonido. Por visitar se entiende acercarse a una distancia determinada a la fuente. Al comienzo de cada prueba se coloca el robot en un lugar equidistante de ambos puntos. En cada punto están situadas (asignadas aleatoriamente) dos fuentes de sonido. El robot, según lo que reciba por sus sensores podrá moverse por el plano activando con diferente velocidad los motores. La función de adecuación (*fitness*) se define a partir de la puntuación de cada una de las pruebas hechas a cada *topo* de la población. La puntuación de una prueba depende de la distancia mínima a cada uno de los dos *faros* o fuentes de sonido. Se restan los valores de las distancias mínimas a una cantidad base y se suma un *bonus* si el topo visita la primera fuente. En cambio, se resta otra cantidad si se visita el segundo faro. La mayor puntuación corresponde con la mejor actuación. En caso de hacer por error una mala prueba, la puntuación sería negativa, pero se pone a 0 para que no pese en exceso en la nota global. La puntuación es un valor absoluto, no depende del entorno ni del comportamiento de otros topos de su generación.

4.1.1. Fuentes de sonido o *faros*

La señal emitida por los faros tiene la estructura de cualquier sonido estéreo. Cada faro emite dos canales, con puntos de emisión separados por cierta distancia (dos altavoces), y cada uno es una onda² con una determinada amplitud variable en el tiempo. Estos sonidos se dispersan normalmente por la superficie siguiendo las leyes de la Física. Ni los bordes del mundo ni cualquier otro elemento del mundo reflejan ni atenúan la señal, con el fin de no hacer más *pesada* aún la simulación del modelo, en la que las operaciones matemáticas y de actualización de la red neuronal requieren una gran capacidad computacional (puede llegar a ser del orden de una hora por cada generación del algoritmo genético, para veinte pruebas de un minuto virtual por individuo de una población de 3000 individuos).

4.1.2. Individuos o *topos*

Los *topos* (individuos o robots de la simulación) se componen funcionalmente de oído externo (atenuación de la señal recibida para cada frecuencia y según el ángulo de incidencia), oído medio e interno (la Transformada de Fourier y los sensores), la red neuronal, la información genética, posición y energía. El valor resultante de la red neuronal se traduce en movimiento a base de cambiar la velocidad actual de los dos motores y ruedas del topo, que

²Un sonido es una onda compleja. Para una descripción mejor consultar el apéndice B.2

se sitúan a ambos lados del individuo. Si los motores no reciben nuevas activaciones, se van frenando. La velocidad de giro depende de la diferencia entre las velocidades de los motores.

La simulación de estos robots virtuales de dos ruedas se hace simétrica por diseño (Husbands et al., 1994), con el fin de facilitar la formación de estructuras similares a los vehículos de Braitenberg (ver la subsección 2.9.4). El robot tiene dos oídos y dos motores. La diferencia de velocidad entre las ruedas causa el giro del robot. Las neuronas motoras producen la activación de los motores proporcionalmente a su nivel de activación, acelerando o frenando en función del tiempo entre pulsos que llegan al motor. Cuanto menor es la media de los tiempos de todas las neuronas motoras, más rápidamente gira el motor.

4.1.2.1. Sensores

Los sonidos llegan a los dos oídos de los topos, a ambos lados del cuerpo, con un ángulo de separación variable, codificado genéticamente. En los oídos se mezclan teniendo en cuenta los retardos por las diferentes distancias y la amplitud en función de la frecuencia y del ángulo de incidencia de cada sonido (oído externo u oreja). Posteriormente, se procesa el trozo de señal recibida para ponerla en función de la frecuencia, a través de la *Transformada de Fourier* (ver apéndice B.2), una simplificación de lo que hace el oído interno o *cóclea* en los seres vivos. Esta “información” ya puede ser usada por la red neuronal.

Los sensores reciben la amplitud de ciertas franjas de frecuencia cercanas a su frecuencia central (en la que más se excitan) y producen una intensidad que pasan a su neurona asociada. Este proceso refleja la vibración de los cilios. Tienen como parámetros un umbral, la intensidad de saturación y la frecuencia central y amplitud (de las frecuencias) de la sensibilidad.

La adquisición del sonido en la parte del *oído externo del robot* se simula con el modelado de un micrófono cardioide, nombre que deriva de la gráfica en forma de corazón obtenida si se dibuja en coordenadas polares la intensidad del sonido recibido en función del ángulo de incidencia.

Por tanto, se incluye la física de un micrófono real al aplicar una función cardioide a la señal recibida. En concreto, se atenúa el sonido (multiplicando la amplitud de cada frecuencia) proporcionalmente al ángulo de incidencia. Se multiplica por cero si el sonido proviene de atrás (180°), por uno si viene del frente, y por 0.5 si viene de un lado (90°), y en otros ángulos de forma proporcional con precisión de un grado.

La emulación de un micrófono nos permitirá corporizar el diseño en un robot real. Estos dos micrófonos, que actúan como oídos externos, tienen un ángulo (uno a cada lado) del eje longitudinal del robot (ver la figura 4.1). Este ángulo se determina genéticamente como una parte de la estructura de los sensores.

Si se simplifican variados efectos no lineales, se puede decir que la cóclea realiza la transformada de Fourier a las ondas sonoras, y el resultado de la transformada es lo que recibe el Sistema Nervioso (Handel, 1989).

La transformada toma una señal representada en función del tiempo (un muestreo de sonido como el que encontramos en un audio-CD) y produce un vector de números complejos que representan la amplitud y fase de cada intervalo de frecuencia (un espectro de frecuencias). En programas de ordenador para procesamiento de sonido se puede observar un sonido con este tipo de representación (figura 4.2).

Los sensores seleccionan valores de la amplitud de onda de la transformada, y alimentan las neuronas sensoras con su peso de activación (definido genéticamente). Los sensores son una abstracción de los descritos en Nieder y Klump (1999) (ver figura 4.3, tomada del mismo texto). Este sistema usa la Transformada Rápida de Fourier (FFT), con lo que se divide el espectro de frecuencia usado (3 kHz) en 64 bandas proporcionales, porque este algoritmo




Figura 4.1: Proceso auditivo.




Figura 4.2: Espectro de frecuencias del canto de un pájaro. Tiempo en segundos (horizontal), frecuencia en Hz (vertical), y las mayores amplitudes de onda en amarillo (color claro).




Figura 4.3: Datos experimentales del umbral de activación para cada frecuencia, medidos con electrodos implantados en estorninos. La línea continua muestra el umbral de activación para cada frecuencia. La neurona reacciona de forma más intensa cuando la línea situada en el punto que relaciona su frecuencia y amplitud es larga (Nieder y Klump, 1999).

necesita potencias de dos³. Cada banda tiene un rango de 47 Hz, con lo que un sonido muy bajo en frecuencia se representa en la primera franja. Este sonido excitará un sensor cuya frecuencia característica esté en la segunda banda, pero con menos intensidad.

Los sensores pueden reaccionar a frecuencias cercanas a su frecuencia característica, según sus parámetros definidos genéticamente. Hay sensores *anchos* y *estrechos*, dependiendo de si tienen un valor alto en este parámetro. También responden según un umbral y un nivel de saturación. Estos valores definen una línea en forma de V similar a la de la figura 4.3, en la que podemos ver datos reales⁴ (Nieder y Klump, 1999). La neurona se activa para cada frecuencia e intensidad proporcionalmente a la longitud de las líneas verticales correspondientes de la gráfica, muchísimo más grandes en el interior del área marcada por la línea continua.

4.1.2.2. Red neuronal

Las neuronas asociadas a sensores (neuronas sensoras) forman parte de la red neuronal. Ésta es un conjunto de neuronas conectadas por axones que responden al modelo de red neuronal recurrente y dinámica. Por recurrente se entiende que puede tener ciclos, ya que no hay restricciones a la conexión entre cualquier par de neuronas. Con dinámica indicamos que su funcionamiento no es discreto, sino que mantiene una continuidad, y que las neuronas no se activan con una función de tipo *sigmoideo*, sino con un patrón de activación tomado (de forma simplificada) de las neuronas naturales (ver la figura 3.3, que representa la forma de activación a través de la fórmula 3.8 tal como se describe en la sección 3.4.3). Por ello, si se sobrepasa un umbral variable, se produce un pulso (*spike*)

³Una aproximación que dividiera en octavas (una escala exponencial) podría ser más realista desde el punto de vista biológico.

⁴Texto original de la figura 4.3: *Ejemplo de una matriz de respuesta que define las características de ajuste. La altura de las barras indica el número de impulsos en la combinación frecuencia-nivel. Una FTC (línea continua) y zonas laterales inhibitorias (líneas de puntos) se han añadido de acuerdo con el criterio de umbral descrito en el texto.*




Figura 4.4: Estructura interna de un individuo. Conexiones a motores en rojo, axones en naranja (pesos positivos) y azul (negativos), y conexiones desde sensores en celeste y morado.

que inhibe posteriores disparos excepto los que coinciden con la frecuencia de disparo de esa neurona, ya que esto cambia el umbral. Además, se tiene en cuenta una distancia (determinada genéticamente) entre neuronas, por lo que un pulso tarda cierto tiempo en recorrer un axón, y puede haber más de un pulso en cada axón.

Las sinapsis inhibitorias pueden bloquear el pulso de la neurona post-sináptica. Las sinapsis no retienen el valor, con lo que los únicos mecanismos para retrasar la respuesta al estímulo son los retardos axonales y los ciclos en la red.

La topología de la red neuronal y sus conexiones se muestra en la figura 4.4. Está compuesto de dos subredes totalmente recurrentes, simétricas y conectadas parcialmente.

4.1.3. Algoritmo genético

Para codificar toda esta información y que el algoritmo genético proporcione una evolución, se ha escogido una representación directa, en la que se evolucionan todas las posibles combinaciones neuronales, todos los axones. Esta solución por completo técnica y pragmática esquiva el gran problema de la *morfogénesis* a costa de tener una baja escalabilidad (ver los puntos 3.10.2 y 1.3).

Aun así, los sensores, parte básica en el paso de información entre el entorno y el agente, son fácilmente evolucionables, ya que seleccionan y procesan una franja de los datos y pasan la activación a la red neuronal.

El funcionamiento del algoritmo genético escogido es *elitista*, en el que el 25 % de los individuos de la generación con mejor puntuación pasa a la siguiente generación y el resto de los puestos en la población de tamaño fijo se llena con el *cruce* de dos progenitores. Estos se eligen entre el 75 % mejor de la población anterior (se incluye la élite y se eliminan los peores individuos), con una probabilidad uniforme.

El problema de parada

El *problema de parada* consiste en la imposibilidad de predecir si una Máquina de Turing (un ordenador imaginario infinito) va a parar con determinada entrada o va a ciclar indefinidamente. Parece extraño nombrar este problema teórico en este entorno, pero se presenta un problema análogo cuando se necesita saber si mediante algoritmos genéticos se va a encontrar una solución o no y en cuánto tiempo. En este caso es fácil relativamente plantear una medida sobre la capacidad de un individuo de ser solución, y por tanto de parar la ejecución cuando se considera tener ya una solución correcta o por lo menos aceptable al problema al que se aplica el método. Sin embargo, cuando todavía no se ha *encontrado* una solución en el vasto espacio n-dimensional de un problema complejo, no se puede decir si falta evolucionar para encontrarla, o por el contrario la búsqueda se ha *atascado* en un máximo local, hace ciclos, o resulta imposible virtualmente encontrar la solución con la configuración actual de la simulación. Una práctica habitual (Romero, 2007) es terminar la ejecución con un número de generaciones estimado inicialmente, suponiendo que si no se ha llegado a una solución es que no es posible alcanzarla ya que casi siempre se llega a una solución antes de agotar ese límite.

En la simulación que se ha implementado en esta memoria la multitud de parámetros impide prever la dificultad y por tanto el número de generaciones necesario para obtener una solución o suponer su inexistencia. Estas cantidades de parámetros no se encuentran en los trabajos de desarrollo de técnicas que mejoran la eficiencia de los algoritmos genéticos, como el citado de Romero (2007).

4.1.4. Experimento y función de adecuación (*fitness*)

TOPOS modela el clásico experimento de la *caja de Skinner* (ver subsección 2.9.3). Una rata en una caja debe (o puede) pulsar una palanca u otra. Las ratas aprenden a relacionar el premio o castigo que reciben al apretar una palanca con el estímulo asociado a la palanca (una luz, una imagen, un sonido).

El experimento consiste en colocar en la superficie dos faros con diferentes sonidos y un topo a cierta distancia de ambos. El individuo recibe más puntuación cuanto más cerca esté del faro indicado como bueno, con lo que debe ser capaz de distinguir los sonidos, por ser la única información que tiene para acercarse. Para evitar elecciones al azar o la suerte, se repite la prueba varias veces y se obtiene una puntuación media que es directamente el valor de *fitness* que se usa en el algoritmo genético. Los individuos con baja puntuación no pasan su dotación genética, así que los comportamientos relacionados directa o indirectamente con ella no se heredan. Los genes que ayudan a hacer mejor la tarea resisten la criba y se extienden por la población entera o por parte de ella, según lo determinantes que sean.

4.1.5. Problemas del planteamiento incremental

El problema de la *morfogénesis* hace difícil plantear un acercamiento incremental al mejor individuo, ya que la representación directa limita la flexibilidad de los cruces genéticos. La opción más sencilla es generar individuos de un tamaño suficiente para que en los experimentos sencillos se use una pequeña parte de la red neuronal y sensores, y el resto no influye (se le denomina basura o *junk*⁵). A estos primeros individuos se les presenta un problema sencillo, para encontrar la población semilla del siguiente paso, de forma que entre esa parte no usada y la mutación producen la variedad que debería crear un proceso de morfogénesis. Simulamos de esta forma lo que una cría (un niño) hace naturalmente al descubrir y enfrentarse a nuevos problemas que antes no existían para

⁵Concepto usado en genética al hablar de posible información no usada al no llegar a expresarse, al no tener consecuencias en el fenotipo.

él. La propia capacidad perceptiva del ser define el entorno que existe para él, de la misma forma que para una persona que pierde la audición deja de existir una parte de su entorno.

Sin embargo, como es muy difícil controlar la capacidad de adaptación de individuos con tan pocas variables (si un valor se sale del rango dejan de hacer la tarea y comportan como el peor), resulta más útil empezar siempre desde cero con una población aleatoria que vaya cumpliendo paso a paso, generación a generación, la tarea reflejada en la función de adecuación. Para ello es interesante que ésta permita una cierta proporcionalidad y continuidad entre el comportamiento aleatorio y el que hace la tarea, independientemente de la rapidez, habilidad y estrategia que se sigue para llevarla a cabo.

4.1.6. Evaluación de los comportamientos de los individuos en las pruebas

En general, entendemos que un individuo, un *topo*, es capaz de distinguir un estímulo de otro si se acerca al correcto *en la mayor parte* de las pruebas. Esto parece vago e incluso falso, pero sabemos que es imposible evitar confundirse, como por ejemplo al contestar al teléfono y confundir la voz de dos hermanos. El problema en la evaluación es distinguir el fallo pasajero de la incapacidad, sin hacer un extenso estudio. Es fácil ver la analogía con la estadística: la muestra debe ser suficiente para hacer los datos fiables, pero el realizar la encuesta a una muestra grande es un gran esfuerzo. Conforme aumenta la complejidad resulta más difícil evaluar comportamientos, pasamos de tener predecibilidad binaria (lo hace o no) a tener que crear una Psicología de los robots basándonos en la estadística (como se hace en la Psicología humana, en la línea del [Conductismo](#)). Di Paolo (2002) llega a esta misma conclusión (ver 3.2).

En vez de usar la puntuación que proporciona la función de adecuación o *fitness*, contamos cuántas veces se realiza la tarea correctamente (*acierto*), en cuántas se falla, y el resto son las veces en las que no es capaz de "decidirse". Con estos datos definimos estos valores:

- eficacia absoluta $e_{fa} = \text{aciertos/pruebas}$
- eficacia relativa $e_{fr} = \text{aciertos}/(\text{aciertos}+\text{fallos})$

Se considera acierto a la acción de acercarse al sonido correcto a una distancia de la cuarta parte de la que separa los faros. De forma simétrica, fallo es acercarse al círculo que rodea el sonido incorrecto del mismo radio.

4.2. Descripción pormenorizada de los elementos del modelo

Después de dar en la sección previa (sección 4.1) una descripción general del modelo, en ésta se dan valores y detalles de la simulación. Es importante recalcar que el objetivo es describir con precisión *qué* se simula, y no el *cómo*, ya que en este trabajo no se hace ningún avance en la programación orientada a objetos en `java`, por poner un ejemplo de técnica usada.

4.2.1. Mundo

En la simulación se usa una unidad de medida que permite establecer proporciones adecuadas. Se denomina *metro* a mil unidades de distancia mínima en los ejes de coordenadas. El mundo o *arena* tiene unas dimensiones de 109 por 106'5 *metros*. La elección de estas cantidades se debe simplemente a la representación en pantalla y no influyen en el resultado de las pruebas por restricciones de máxima distancia a los faros. El individuo tiene 512

puntos de radio y sus ruedas están separadas por esa misma cantidad, por lo que cada una está equidistante del centro y del borde del topo. La orientación del individuo se mide en grados sexagesimales con una precisión de un grado.

El mundo se actualiza en ciclos que duran el tiempo calculado en la variable `increloj` a partir de la frecuencia del sonido y el tamaño de la transformada de Fourier, tamaño determinado por el número de bandas en las que se decide dividir el espectro de frecuencias. Los valores habituales en los experimentos, bajos por cuestiones de eficiencia, son los que se pasan a describir. Los sonidos tienen una frecuencia de muestreo de 6000 Hz, por lo que el sonido más grave es de 1 Hz y el más agudo que pueden contener es de 3000 Hz (por el Teorema de Nyquist, ver el apéndice B, sección B.2). Se elige un valor 64 bandas para dividir ese rango de 3 kHz, por lo que las bandas son de unos 47 Hz de anchura. Para hacer la FFT (ver la sección B.2) se necesitan 128 muestreos, el doble de las bandas. Al haber 6000 muestreos por segundo, se hará una FFT cada $6000/128 = 0'0213$ segundos, valor de la variable `increloj`. Este valor es aproximadamente la quinta parte de una décima, el tiempo que debe haber entre dos sonidos para que un ser humano pueda diferenciarlos como dos sonidos independientes.

4.2.2. Fuentes de sonido o faros

Los dos faros están situados en la mitad del mundo en la horizontal, uno de ellos a dos quintos del límite superior del mundo y el otro a dos quintos del inferior. Según se coloque el topo, cada faro se colocará a su izquierda o a su derecha. Si son faros extra que sólo se usan para producir dificultades como crear ruido, se sitúan en el tercio central de cada dimensión.

Está orientado hacia la derecha, y se tiene en cuenta para emitir al separar los canales por 60 grados al borde del faro. El radio del faro es el mismo que el del bicho, 512 puntos, más o menos medio metro virtual. El faro contiene las coordenadas de su centro y las de los dos puntos emisores de sonido, ya que el sonido emitido tiene dos canales (estéreo o dos mono). Estos “altavoces” están en el límite exterior del faro y separados por 60° . Cada faro abre un fichero de sonido que lleva un prefijo compuesto por la letra *f* y el número en kHz del muestreo en el que está representado el sonido (6, 11, 22 y 44 kHz). Todos los faros emiten simultáneamente sus sonidos.

Se pueden usar dos posibles formatos de sonidos para los faros en los ficheros, el PCM y el FFT. No se permite que haya faros con tipos de fichero (y por tanto con formatos de salida) distintos. El PCM es un formato crudo, es decir, son muestreos alternos de los dos canales (medida de la intensidad de la señal eléctrica que representa el sonido). Cada medida tiene 16 bits de precisión (65536 niveles de intensidad), y con orden Intel-*little-endian*⁶. Si el muestreo ha sido a 6 kHz, hay $6000 \text{ muestreos/s} \cdot 2 \text{ canales} \cdot 2 \text{ bytes/muestreo} = 24000 \text{ bytes/s}$. El formato FFT contiene los pares de amplitud y fase por cada frecuencia en un quantum (tiempo mínimo de ciclo), agrupadas por cada canal.

Sólo en el caso de trabajar con el formato PCM es posible introducir en el sonido los retardos producidos por la distancia entre faros y topos. En el caso de PCM, cada ciclo de un faro consiste en rellenar un búfer con un número de elementos igual al número de bandas de frecuencia multiplicado por dos. En el caso de FFT, se lee un bloque de datos. Cada bloque tiene los coeficientes producidos por la aplicación de la FFT a un sonido con formato PCM. Tenemos tantos coeficientes como bandas, se duplica por ser la parte real y la imaginaria del número complejo resultante de la FFT (que representa amplitud y fase de la banda de frecuencias), se añade 2 por los valores *cerof* y *cerof*, y todo en conjunto se multiplica por el tamaño en bytes de un número de tipo `float` de java en esta

⁶El orden LSB, MSB (*byte menos significativo* y *byte más significativo*) es el *little endian* (el primer número el de menos valor numérico o el más pequeño primero), usado por Intel. La alternativa es el *big endian* usado por Motorola, por ejemplo. En números decimales es como si pusiéramos dos grupos de cifras, el primero con las centenas, decenas y unidades, y después otro con centenas de miles, decenas de miles y miles.

implementación. El punto de lectura en el fichero se sitúa de forma aleatoria y siempre al inicio de un bloque de datos.

Los oídos del individuo realizan la FFT al sonido que reciben si está en formato PCM. Los sonidos se han compuesto anteriormente sumando el valor de los muestreos o asignando al sonido la mayor de las intensidades de la señal en cada frecuencia, copiando la fase de cada onda sinusoidal. Es decir, en el formato FFT se toma como valor en una frecuencia la onda más intensa, anulando la débil.

4.2.3. Los individuos o *topos*

En cada ciclo de actualización del mundo, que dura esas dos centésimas, se compone de varios pasos. El primero es actualizar los faros (las fuentes de sonido), seguidamente se realizan las operaciones para calcular la entrada a los oídos del topo (el individuo), se hace un ciclo en el topo, y por último se miden las distancias a los faros y se comprueba si se termina la prueba. La prueba puede terminar por acierto o fallo (es decir, llegar a uno de los faros), fin del tiempo máximo de la prueba o por exceso de distancia (45 metros virtuales desde el centro del mundo). El ciclo en el individuo incluye la propagación del sonido, la actualización de los datos de los sensores, los motores y un ciclo de la red neuronal.

Para cada topo se calcula la posición de sus oídos (que depende del parámetro genético de ángulo de separación de los oídos), sus coordenadas y pasa a la fase de oír y mezclar el sonido que recibe de los faros. Para ello se obtienen las coordenadas del faro y se calculan la distancia desde cada oído, los ángulos relativos y el ángulo de incidencia del sonido respecto a la orientación del oído. En cada oído la simulación aplica una amortiguación del sonido del tipo cardioide en función de dicho ángulo de incidencia. Esta bajada de intensidad para todas las frecuencias simula un micrófono direccional típico, que es mucho más sensible de forma frontal. De esta forma simulamos el oído externo que permite determinar la procedencia del sonido (ver el apéndice B, sección B.6). Lo percibido por cada oído se va acumulando para posteriormente realizarle la FFT si es preciso, y pasarlo al individuo. Éste suministrará la activación a cada sensor.

Como paso final del ciclo de actualización de los efectores, los valores de activación calculados pasan a añadirse a los motores. Es decir, estos valores calculados producen una aceleración. A partir de la nueva velocidad de los motores (que se mide directamente en puntos por ciclo, debido a `coefmotor`) se calcula la velocidad del topo y el cambio del ángulo, así como las nuevas coordenadas, que se cierran en la superficie del mundo. Se establece un máximo de velocidad de 21'3 puntos por ciclo, es decir, $1000 * \text{inreloj}$ puntos por ciclo, o 1000 puntos por segundo, 1 m/s. De la misma forma, la velocidad mínima es la cuarta parte. Las velocidades e incrementos pueden ser positivas y negativas. Después de todas estas actualizaciones se compensa que los motores aceleren con la simulación de forma simple del rozamiento reduciendo a la mitad la velocidad de ambos motores. Como imagen de este funcionamiento se puede comparar a la forma de controlar las sillas de ruedas en partidos de baloncesto: aceleran con ambas ruedas y para girar frenan la rueda del mismo lado, obteniendo de esta forma una alta velocidad.

Cada topo tiene un estado (posición y velocidad) y una tabla para almacenar el resultado de las pruebas. La separación entre oídos es de 60 grados a cada lado del eje longitudinal. Asimismo tiene la información genética, la expresión de sus sensores, motores y red neuronal.

Un ciclo en un individuo incluye la actualización del sonido recibido en sus oídos, del paso de "datos" a los sensores, el ciclo de la red neuronal y el cálculo de la activación de los motores y del nuevo estado del individuo.

4.2.3.1. Sensores

Los sensores tienen un valor de activación sensorial y un valor de activación neuronal, el peso de la conexión a su neurona, la frecuencia característica (FC) (frecuencia a la que responden con más intensidad), el umbral de activación, la sensibilidad a frecuencias adyacentes a la FC medida en franjas o bandas, la intensidad a la que satura en la FC, la entrada actual, a qué oído y neurona está conectado, y valores análogos a los de las neuronas porque los sensores se disparan de la misma forma. Se calcula la cantidad de activación del sensor por cada banda de frecuencia, teniendo en cuenta que el sensor se activa más en la FC, y se escoge la mayor de las activaciones. El valor de activación sensorial intenta reflejar la figura 4.3. Para eso calcula el máximo de los valores de activación relativa en cada una de las frecuencias según su umbral y máximo. Al resultado de restarle a esta mayor activación el umbral del sensor se le resta también un valor aleatorio entre 0 y 49, con el objetivo de incluir indeterminación en el disparo como indican los estudios en los sistemas vivos y simular la existencia de ruido (ver la sección B.6). El resultado de estas restas se divide entre la cantidad de activación con lo que se obtiene un valor entre 0 y 1. Este coeficiente se va acumulando hasta que se llega a 1, con lo que el sensor dispara. Si la entrada disminuye, el coeficiente decrece y las posibilidades de disparo disminuyen (Handel, 1989). Esta estructura intenta concentrar el trabajo estadístico de miles de cilios y neuronas que tiene un oído humano por cada frecuencia (ver la sección B.6).

El peso de un sensor aleatorio está entre -127 y 255 para que la tercera parte de los pesos sean negativos. La FC de la misma forma se genera de forma equiprobable entre 0 y 3000. El número de franjas abarcadas por un sensor aleatorio está entre 4 y 11. El umbral entre 0 y 19, y a la saturación entre 0 y 250 se le suma el umbral.

Las mutaciones ocurren en los sensores un 5 % de las veces que se copia un valor, y se incrementa o decrementa hasta la cuarta parte, es decir, se calcula un coeficiente entre 0 y 0'25 para multiplicarlo por el valor y después añadirlo o restarlo, operación ésta que también se decide aleatoriamente.

4.2.3.2. Red Neuronal: neuronas y axones

La red neuronal se actualiza de forma especial. En primer lugar, se pretende actualizar de forma que un disparo completo de una neurona dure una décima de segundo (ver el gráfico del disparo de neurona en la figura 4.5). Debido a esto, por cada quantum de sonido (valor increloj) hay $\text{increloj}/0'1$ disparos de neurona. Con los valores usados tenemos 0'213 disparos por quantum de sonido o ciclo de actualización del mundo. Si un disparo de neurona está compuesto de 32 valores precalculados, se deben usar $32 \cdot 0'213 = 6'82$ de ellos y por tanto las neuronas harán 6 ciclos de actualización de sus valores (sinapsis, salida. . .) por cada quantum de tiempo determinado por el número de bandas y la frecuencia de muestreo del sonido de los faros. Estos “miniciclos” se pasan a denominar *tics*.

La fórmula que describe el disparo de la neurona es la siguiente:

$$a_t = e^{-\alpha} \cdot \cos(\beta t) \quad (4.1)$$

La latencia son dos ciclos de disparo de neurona, es decir, 64 tics. Cada uno de los valores precalculados para el disparo de neurona se usan en un tic. Para permitir que una neurona se dispare más rápidamente que otra, se introduce un coeficiente que tiene el valor de 1 si sigue el comportamiento descrito.

El ciclo de actualización de los efectores comprueba cada neurona para añadir su valor de activación al de los motores. Por cada una obtiene una cantidad que, cuanto más pequeña es, más activa el motor conectado a la efectora. Si han pasado más tics que la latencia, la cantidad calculada es el valor de latencia, y en caso contrario la cantidad de tics pasados desde el último disparo. Si la neurona es inhibitoria, en el caso de haber sido el disparo lejano inhibe con el valor de latencia, y si el disparo es cercano inhibe con la suma de la latencia y el tiempo que hace del último disparo. Todos los valores se promedian, se normalizan dividiéndolos entre la latencia, y se




Figura 4.5: Pulso generado a partir de la fórmula 4.1, con el que se simula burdamente el disparo de una neurona. A los tres primeros valores se les asigna el valor 0. Los valores son $\alpha = 1,666$ $\beta = 2,5\pi$ y $t = 0'1 \cdot \text{paso}/32$ s.

multiplican por el coeficiente que indica la velocidad de los motores. El valor de cada motor sirve para cambiar la velocidad y posición del individuo.

Una neurona tiene el valor de activación actual, el valor temporal que sirve para calcular el nivel de activación que recibe la neurona de otras en el ciclo actual, el umbral de disparo que se suma al de activación para calcular si hay nuevo disparo, el índice que cuenta los tics desde que la neurona se disparó, los booleanos que indica si la neurona es efectora o inhibidora, y si es efectora del lado izquierdo, del derecho o de ambos. Si ha pasado un cuarto del tiempo de disparo de la neurona, se comprueba si se puede disparar de nuevo al superar el umbral la suma de la activación anterior más la suministrada por la última actualización en este ciclo. Si la neurona se dispara el valor de índice vuelve a 0, con lo que en los próximos ciclos de la red neuronal la neurona seguiría su dinámica de disparo aunque las entradas fueran nulas. Si recibe disparos puede volver a dispararse si la entrada es más fuerte que la distancia entre su activación y el umbral. El valor temporal de entrada no se añade a la curva de disparo, por lo que se aísla por completo las entradas de la neurona de la salida. Este valor sólo sirve para saber si la neurona debe dispararse o no.

El disparo de la neurona se describe con la combinación de dos funciones matemáticas tras el siguiente filtro: en los primeros tres tics se devuelve 1, disparo completo, y más allá de los 32 tics, el resultado es 0, el equilibrio. El resto de los valores vienen de la aplicación de una caída exponencial multiplicada por un coseno que proporciona una oscilación que simula el periodo de refracción y el de rebote (ver el punto 3.4.3). Todas las neuronas tienen la misma velocidad de disparo.

La activación de una neurona se calcula empezando por sumar el valor de activación de su sensor por el correspondiente peso, en el caso de ser neurona sensora. Posteriormente se visitan los axones (el número de axones es igual al de neuronas definidas en la información genética) y se va acumulando su activación por su peso en el valor temporal de la neurona. En este cálculo se toman los retardos para calcular la activación de la neurona tiempo atrás, el necesario para que el pulso viaje por el axón hasta la neurona actual. Si se encuentra un pulso cercano al disparo y con peso negativo se inhibe la neurona aunque otras entradas permitirían dispararla.

4.2.4. Pruebas

Para realizar una prueba el individuo se coloca equidistante de los dos faros. Esto se lleva a cabo dándole como coordenada en vertical el punto medio, y como horizontal el resultado de combinar dos cantidades. La primera se elige de forma equiprobable entre $3/10$ y $7/10$ de la dimensión horizontal del mundo, con el fin de situar al individuo a la izquierda o a la derecha del eje vertical en el que se colocan los dos faros. El segundo valor es un número aleatorio entre 0 y $2/10$ de la dimensión horizontal del mundo, para hacer más difícil un movimiento automático alejando según esta cantidad de forma variable. El individuo se encara a los faros asignándole el valor 0 a su ángulo si debe ir a la derecha (en coordenadas absolutas) para dirigirse hacia los faros, y 180 si debe ir hacia la izquierda. Si se dieran otros ángulos podrían aprovecharse y no desarrollar el comportamiento de taxia.

Cuando termina una prueba se evalúa la capacidad del individuo para realizar la tarea según lo conseguido en esa prueba (se calcula el valor de adecuación o *fitness value*) y se prepara una nueva prueba para una *reencarnación* del topo. El primer paso es recolocar los faros de forma aleatoria, que en realidad se hace colocando aleatoriamente el individuo a izquierda o derecha del eje vertical del mundo, donde se colocan los faros. La otra operación es reposicionar la reproducción del sonido en un nuevo punto. Si era la última prueba de este individuo, se calcula una puntuación final y se añaden datos a los informes. Al completar todas las pruebas de una generación se obtienen las estadísticas finales de la misma y se pasa a generar la siguiente generación y evaluarla.

4.2.5. Algoritmo Genético

La nueva generación de topos se crea aplicando los mecanismos de un algoritmo genético. Tiene como primera fase la ordenación de los individuos según la puntuación global en las pruebas de la generación terminada. Los que pertenecen a la élite se copian directamente y se preparan para la siguiente. Se ha tomado como élite a la cuarta parte con mejor capacidad de la población. El resto de puestos en la población, los que no se rellenan con la élite, son generados por cruce de la información genética de dos padres distintos, elegidos aleatoriamente de la población, desechando la cuarta parte con peores capacidades, es decir, con menor valor de adecuación.

En la información genética se definen como constantes la cantidad de ocho neuronas, seis conexiones eefectoras que activan o frenan los motores, y seis sensores. El número de elementos será distinto en el individuo final dependiendo de si se expresan o no de forma duplicada los datos buscando una simetría lateral, simulando dos hemisferios “cerebrales”.

Se generan individuos de forma aleatoria para la primera generación creando tantos sensores y neuronas como indican las constantes anteriores. Se numeran las neuronas y serán eefectoras tantas neuronas como diga la cantidad de conexiones eefectoras (las de número de orden mayor), y estarán conectadas a los sensores de forma ordenada las primeras neuronas (número de orden menor). El valor de motor es un número al azar de forma equiprobable entre 1 y 200 . De la misma forma, la separación entre oídos es un valor aleatorio entre -29 y 119 .

El cruce entre dos estructuras de datos que componen la información genética de cada uno de los progenitores tiene varios pasos. El primero calcula dos puntos de cruce de tal forma que si tenemos ocho neuronas (numeradas de 0 a 7) y generamos aleatoriamente los valores 3 y 6 , de un progenitor se copiarán las neuronas 4 y 5 , y del otro las 7 , 0 , 1 y 2 , uniendo los extremos para mantener un número constante de neuronas y facilitar así la evolución. Las neuronas que se eligen como cruce son creadas mezclando las neuronas cruce de ambos progenitores, eligiendo aleatoriamente valores. En el resto, copia los datos de cada neurona y sus conexiones, sus sensores si tienen, y los valores de la velocidad del motor y la separación entre oídos. Cada vez que copia un valor, aplica los coeficientes de mutación para decidir si se debe hacer una mutación, y cuánto se varía. En concreto, se muta con una probabilidad del 10% , y el dato se multiplica por resultado de sumarle uno a la sexta parte de un valor aleatorio generado con

una distribución normal (gaussiana) con media 0 y desviación estándar 1. De esta forma se multiplica por un valor que en la mayor parte de las veces estará entre 0'5 y 1'5 y muy probablemente cerca de 1'0.

Al expresar dos veces la información genética duplicamos el número de sensores, por lo que tendremos seis a cada lado. Sin embargo, no se duplica el número de neuronas, sino que se multiplica por 1'5 y se “montan” los dos hemisferios y tenemos doce neuronas. Al tener en la información genética el grafo de conexiones entre neuronas y otros elementos la expresión es casi directa, en una de las dos veces de forma especular. Una neurona efectora puede conectarse a uno de los dos motores o a los dos.

La función de adecuación (en inglés *fitness function*) toma como base un valor de 100.000 (1E5) que modifica restándole diez veces el cuadrado de la mínima distancia al faro al que debe acercarse, y sumándole el cuadrado de la mínima distancia al faro del que debe alejarse. Mejorará su valor de adecuación minimizando la primera distancia y maximizando la segunda. Si el topo se acerca a una distancia inferior a la cuarta parte de la distancia que hay entre los faros, el faro se considera visitado. Si se debía acercarse a ese faro, se le suma un *bonus* de 300000 (3E5), y en caso contrario un *malus* de igual cantidad. No se permiten valores de *fitness* negativos, para no penalizar en exceso un comportamiento anómalo.

El sonido se trata amortiguando su intensidad de forma proporcional al cuadrado de la distancia entre el faro y el topo. Posteriormente se calculan los ángulos de incidencia del sonido en los oídos, restando la separación del oído respecto al eje al ángulo relativo de incidencia del sonido respecto al eje del topo. Con estos ángulos se aplica la cardioide al sonido y se añade al oído.

Al expresar la información genética hay valores que pasan de ser numéricos a booleanos. Es el caso de si un sensor es del oído izquierdo o del derecho, ya que si se tiene un valor mayor de 64 es derecho en el primer hemisferio, e izquierdo en el segundo, completamente especular. Los motores tienen un valor entre 0 y 1 para indicar si son del lado izquierdo, derecho, o ambos. Esto sirve al igual que la separación de oídos para pasar de ser una conexión activadora a inhibitoria con una mutación, paso que puede mejorar notablemente las capacidades del individuo.

Si se expresan dos hemisferios que se solapan, los valores de las neuronas 0 a la 3 se escriben una vez, con sus axones o conexiones salientes, y las neuronas 4 a la 7 son reescritas por el segundo hemisferio, que empieza a escribir la imagen especular de la neurona 0 en la posición 11. De esta forma son especulares la 0, 1, 2 y 3 y la 11, 10, 9 y 8. Los axones se conectan de la misma forma, con el detalle de que no se reescriben los axones impares, con el objetivo de evitar una simetría total que incapacita a los individuos en las pruebas realizadas.

Una neurona será inhibitoria si su valor genético es mayor de 0'8, es decir, con una probabilidad del 20 % si el individuo se genera aleatoriamente.

Un axón tiene como máximo retardo el valor de 64 tics, el doble de la duración de un disparo de neurona. El peso máximo es de 8 cuando se trata de generar aleatoriamente un individuo. El mínimo es -2'66, un tercio de 8 en valores negativos. El retardo es 1 más un aleatorio entre 0 y el máximo retardo.

Ejecuciones y resultados




Figura 5.1: Trayectorias espaciales de un robot resultante de la evolución, colocado en varios puntos de partida. El robot se acerca *instintivamente* al faro que emite el sonido A y evita el faro B.

Llamamos experimento a la ejecución del algoritmo genético con dos sonidos determinados. La población inicial de robots virtuales se genera aleatoriamente. Cada robot es evaluado un número de pruebas y recibe un




Figura 5.2: Máximos y medias de los valores de la función de adecuación (eje Y) de los individuos de cada generación (eje X) en una ejecución del algoritmo genético.

valor de adecuación, o puntuación, que se usa para la selección de los más adecuados en el algoritmo genético. En las figuras 5.1 y 5.2 se pueden ver las trayectorias de un individuo de la élite y los valores de la función de adecuación en el experimento, respectivamente. Al final de la ejecución se lleva a cabo la medición de la eficiencia de los individuos pertenecientes a la élite de la última generación. Con estos datos se genera un gráfico que muestra la capacidad de los mejores robots a la hora de realizar la tarea de discriminación de sonidos y la navegación hacia uno de ellos. Cada gráfico contiene dos histogramas, uno para la medida EFA y otro para EFR, eficacias absoluta y relativa. Recordemos la definición de estos valores:

- Eficacia Absoluta $EFA = \text{aciertos}/\text{pruebas}$
- Eficacia Relativa $EFR = \text{aciertos}/(\text{aciertos}+\text{fallos})$

5.1. Experimentos que comprueban la corrección del sistema

Cada experimento está parametrizado por una infinidad de valores. La mayor parte se mantienen entre experimentos, y sólo algunos se eligen para obtener el comportamiento. Dada la elevada cantidad de tiempo necesaria para cada una de las ejecuciones, no se realiza una exhaustiva búsqueda de los rangos en los que se obtiene un comportamiento satisfactorio del algoritmo genético. Si se optimizaran los mecanismos de tal forma que bajara dicho tiempo, sería factible hacer un estudio de los valores interesantes de los parámetros.

La mayor parte de los experimentos terminan cuando el robot llega a las inmediaciones, es decir, elige uno de los sonidos.

Para comprobar que el sistema funciona correctamente, y para observar comportamientos que pueden ser más o menos triviales, se han preparado varios experimentos, denominados por las iniciales del tipo de sonido usado (que se marcan con las mayúsculas). Los experimentos son los siguientes (de izquierda a derecha y de arriba a abajo en la figura 5.3):

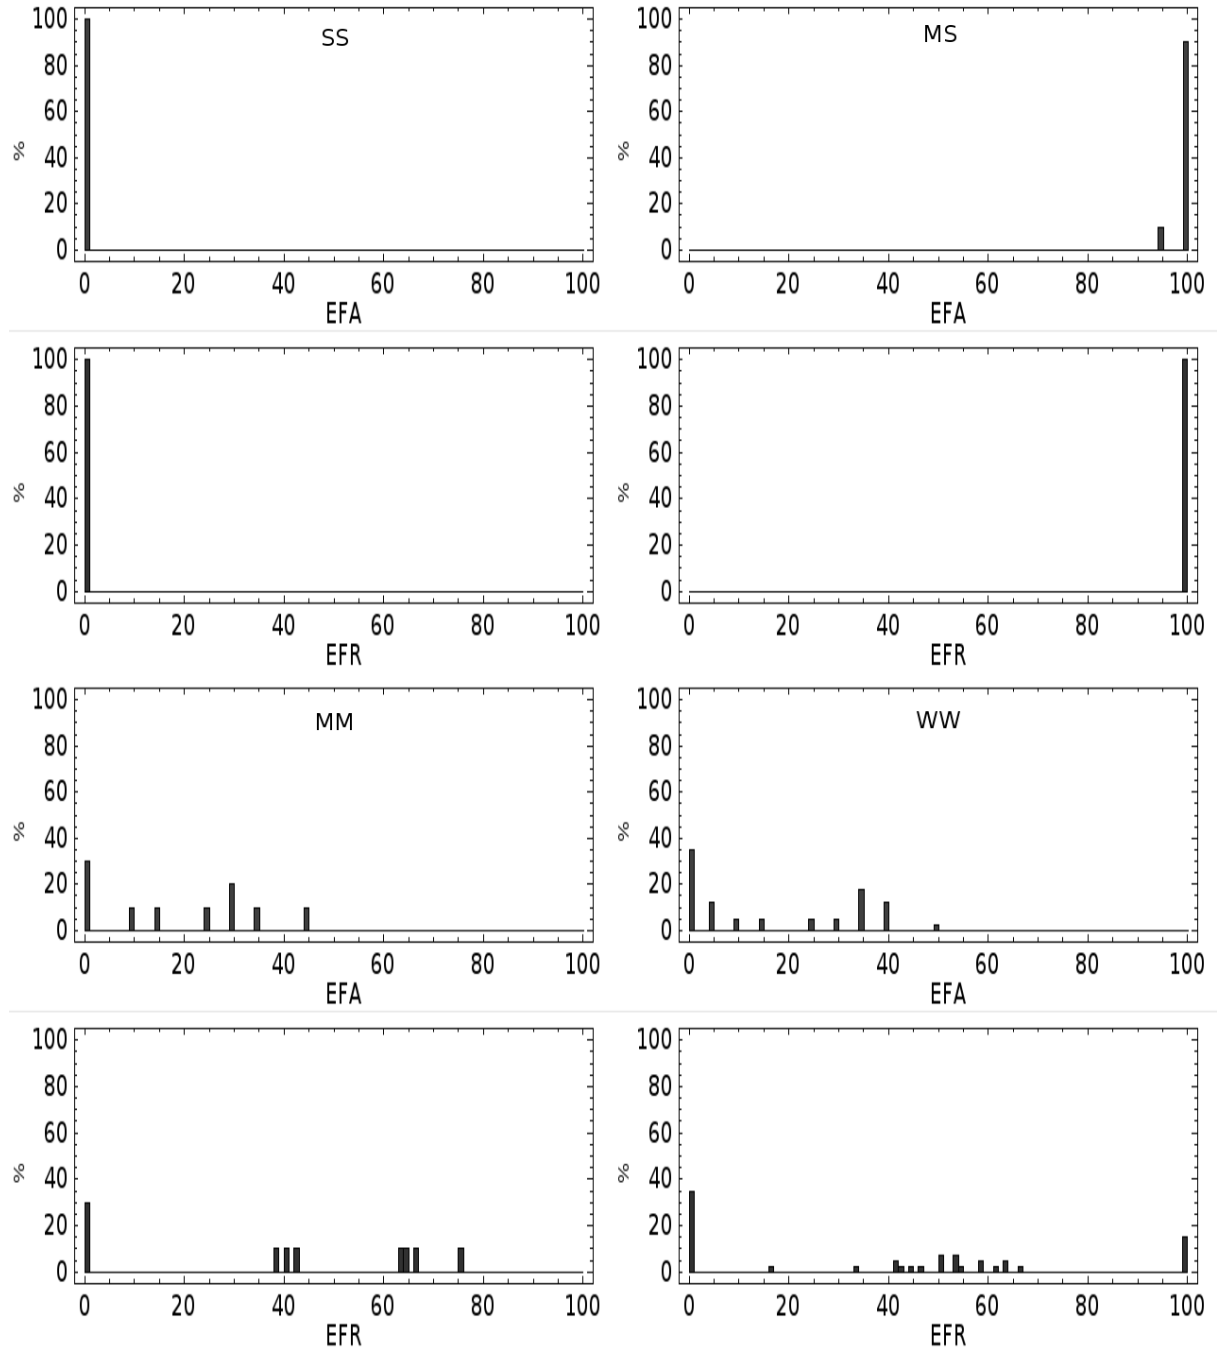


Figura 5.3: Experimentos básicos que prueban la corrección del sistema, con dos histogramas por experimento, para EFA y EFR (superior e inferior, respectivamente). Los histogramas representan la cantidad de individuos que obtienen cada porcentaje de efectividad.

Dependencia del estímulo (Experimento SS): cuando los dos faros no emiten ningún sonido. Las eficacias absolutas y relativas son 0 para todos los individuos. Los robots sólo pueden navegar como respuesta a un estímulo auditivo.

Fonotaxia positiva (Exp. MS): en este experimento la población evoluciona hasta identificar un muestreo (sonido) de Música en una fuente, cuando el otro faro es Silencioso. La fuente a la que tienen que acercarse es la que emite la Música (la primera letra en el código de dos letras que define el experimento). En este experimento se obtiene el típico comportamiento de los vehículos de Braitenberg 2b (fonotaxia positiva) con eficacias cercanas al 100 %.

Incapacidad de distinguir sonidos idénticos (Exp. MM y WW): en este caso se emite desde cada faro el mismo sonido de música, aunque el punto de comienzo de emisión del sonido se elige distinto para cada fuente. Los robots tienen que acercarse al faro correcto, pero como los dos emiten lo mismo, no hay pistas para navegar. La consecuencia es una baja puntuación en cuanto a aciertos, y la misma cantidad de aciertos y de fallos. La mayor parte de los individuos de la élite (30 %) obtienen un 0 % de efectividad.

El experimento WW es básicamente el mismo, pero cambia porque la señal es constante en el tiempo y en frecuencia, por ser ruido blanco (*White*). La eficacia relativa sigue una distribución normal con media en el 50 % de aciertos y fallos, más algunos individuos con resultados iguales a 0. Al igual que en el experimento anterior, hay cierto número de robots que hacen la tarea a veces y obtienen altas puntuaciones en la eficacia relativa, pero baja eficacia absoluta (hasta el 35 % no da respuesta correcta o simplemente no responde, es decir, EFA es 0).

Estos experimentos muestran que los robots necesitan la capacidad de diferenciar los sonidos para llevar a cabo la tarea de navegación hacia el sonido correcto.

5.2. Eficacia de Topos en el reconocimiento de señales

Los experimentos descritos en la sección 5.1 prueban la corrección del sistema TOPOS. Seguidamente se analiza la capacidad de los individuos para reconocer y distinguir señales estructuradas.

5.2.1. Reconocimiento de una determinada intensidad de señal

Los ruidos rosa y blanco son habituales en la naturaleza. El blanco, como ya se ha dicho, tiene la misma intensidad para todas las frecuencias, mientras que en el rosa la intensidad decrece exponencialmente según sube la frecuencia. Un ejemplo de ruido blanco es el de la radio o la televisión en caso de no sintonizar una emisión. En la figura 5.4 se presentan los resultados del experimento PW (rosa y blanco). Es decir, se debe alcanzar la fuente del sonido rosa y evitar la del blanco. Como se puede ver, los individuos de la élite resultante de la evolución pueden seleccionar correctamente el faro rosa con una eficacia cercana al 100 %. Una eficacia relativa del 100 % significa la ausencia de errores, es decir, que no se equivocan.

Un experimento que tenga como objetivo el inverso (alcanzar el blanco y evitar el rosa) da aproximadamente los mismos resultados. Otros experimentos con dos sonidos consistentes en dos partes ligeramente diferentes de una canción de rock también dan buenos resultados.

El experimento PW también muestra que los robots pueden elegir un sonido con menos amplitud para la mayoría de las frecuencias, y evitar el sonido con más volumen, el ruido blanco.

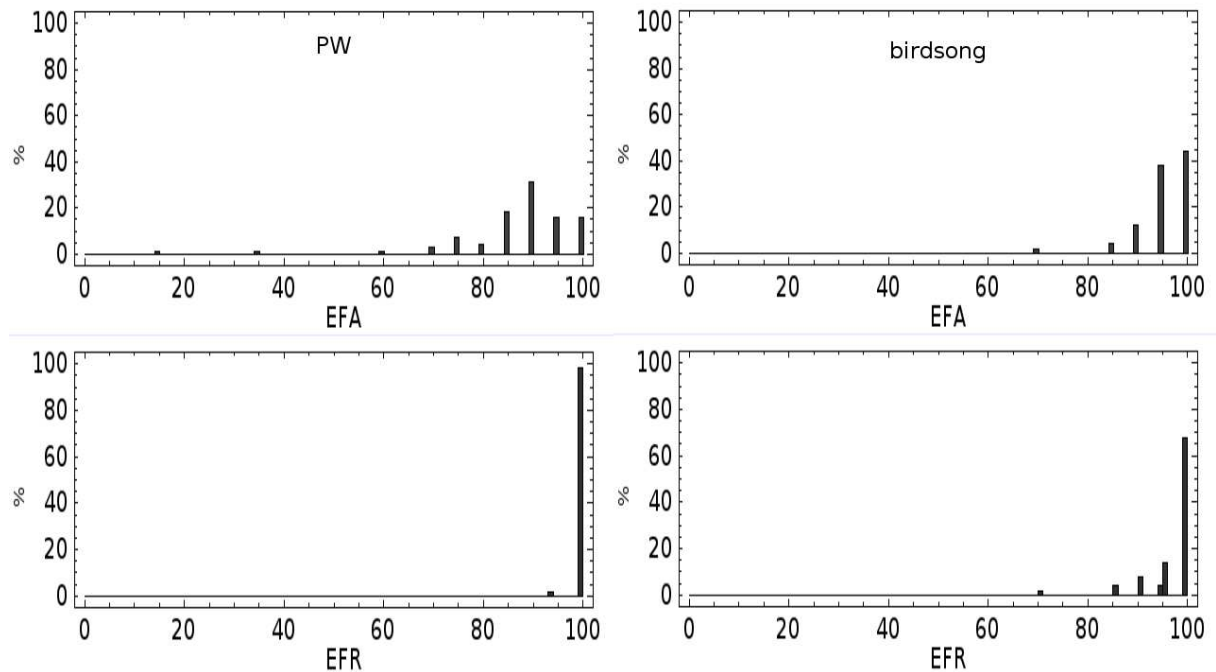


Figura 5.4: Histogramas para el experimento que usa ruido rosa y ruido blanco (en la izquierda), e histogramas del experimento con dos cantos de pájaro de la figura 5.5 (en la derecha).

5.2.2. Reconocimiento de una determinada secuencia temporal

En el experimento de la derecha en la figura 5.4 se usan dos sonidos compuestos a partir de la canción de un pájaro, en concreto un canario. También se podrían elegir otros sonidos. Los dos suenan simultáneamente y el punto de comienzo al emitir es aleatorio. En el gráfico 5.5 se observan dos secuencias, llamadas *XYZ* y *XZY*. La superior se usa en un faro y la inferior en el otro. Nótese que la única diferencia es el orden en las partes que forman los sonidos, como ocurre en las palabras “*per*” y “*pre*”. Los dos suenan simultáneamente pero el punto de inicio es aleatorio.

Al plantear como única diferencia el orden de las partes, evitamos que el robot use el “truco” de discriminar los sonidos filtrando frecuencias con los sensores, tal como hacen ciertos animales (y probablemente se hace en otros experimentos que no se plantean así). Como ejemplo se puede poner el usado por Lund et al. (1997) para crear grillos robóticos que sólo reaccionan al *cricrí* de su especie, por encontrarse en una determinada frecuencia. Con este formato de experimento se necesita la extracción de características temporales.

La figura 5.4 muestra las eficacias relativa y absoluta en el reconocimiento de tan complejas señales. Casi la mitad de la élite realiza la tarea perfectamente (EFA del 100%) y casi todos (más del 80%) reconocen el sonido correcto. El comportamiento de los robots cuando realizan la tarea de navegación se puede ver en la figura 5.1, y los los valores de adecuación en el algoritmo genético en la figura 5.2.

5.3. Comportamiento robusto de Topos frente al ruido y a sonidos de fondo

Los ruidos de fondo interfieren en la inteligibilidad y en la facilidad de percibir sonidos. Se llama ruido en general a todo sonido que *molesta* al oír, es decir, dificulta la tarea de percepción al modificar la señal. Los siguientes




Figura 5.5: El espectro de frecuencias de los sonidos (extraídos del canto de un canario) para el experimento preparado para probar el reconocimiento de una secuencia temporal. Tiempo en segundos (horizontal), frecuencia en Hz (vertical), y las mayores amplitudes de onda en amarillo.

experimentos muestran la robustez de los resultados frente a sonidos que perturban en las tareas de reconocimiento de cantos de pájaro, descritas en el anterior experimento.

En el primero de estos experimentos hay dos sonidos añadidos que se emiten desde puntos aleatorios (cerca de los faros principales). La posición de cada ruido cambia en cada prueba, así como el punto de inicio en la secuencia de reproducción. Estos sonidos se componen de diferentes golpes de batería (generados en un dispositivo MIDI) y música rock.

En las figuras 5.6 y 5.7 los datos revelan que les es más difícil a los robots distinguir los dos cantos de pájaro, comparando con los histogramas de la derecha en la figura 5.4 y 5.2, respectivamente. Pueden conseguir realizar la tarea la mayoría de las veces pero no siempre, debido a que la misma perturbación impide oír al situarse demasiado cerca y ocultar el propio sonido. En concreto lo consiguen un 85 % de las veces (EFA), y la proporción entre aciertos y fallos (EFR) no es tan buena como en el experimento (sección 5.2).

Las figuras 5.8 y 5.9 muestran que la capacidad para hacer la tarea disminuye conforme crece el número de fuentes adicionales de ruido blanco. Es más difícil, aunque no imposible, distinguir entre los cantos de pájaro




Figura 5.6: Histogramas para el experimento con dos sonidos de fondo adicionales compuestos de batería y música rock.




Figura 5.7: Máximos y medias de los valores de la función de adecuación (eje Y) de los individuos de cada generación (eje X) en una ejecución del algoritmo genético para el experimento que tiene ruidos de fondo. Comparar con la figura 5.2.




Figura 5.8: Histogramas para el experimento hecho con *dos* fuentes adicionales de ruido blanco.




Figura 5.9: Histogramas para el experimento hecho con *cuatro* fuentes adicionales de ruido blanco.

cuando los ruidos de fondo son ruido blanco, si comparamos a los ruidos compuestos de música y batería (ver figura 5.6). Esto es debido a que estos últimos emiten con muy baja intensidad en la mayoría de las frecuencias y las que sirven para diferenciar los sonidos se perciben más fácilmente que cuando el ruido los oculta por su intensidad constante para todas las frecuencias. De todas formas, los robots consiguen bastante buenas puntuaciones (teniendo en cuenta la dificultad del problema), e intentan hacer las pruebas tan bien como les sea posible (comparar con la figura 5.3).

5.4. Sonidos con partes de silencio

Los sonidos en este experimento están formados por la concatenación con diferente orden de dos trozos cortos del canto del mismo canario con una parte de silencio, que se denotan con *YZS* y *ZYS*. Los trozos tienen diferentes frecuencias en las que existe sonido, con lo que se debe comparar la salida de dos sensores diferentes. El silencio es una dificultad adicional para mantener la trayectoria, puesto que la fonotaxia positiva por la estructura de vehículo de Braitenberg 2b (ver sección 2.9.4) les lleva hacia el único sonido que se oye en un cierto momento al ser los dos sonidos simultáneos. El silencio se observa en las gráficas de la figura 5.10 a la derecha, en forma de línea en el 0 o señal plana (arriba) y de zona negra en el formato de frecuencias (abajo).

Con una población de 800 individuos y 5 pruebas por individuo en cada generación, se necesitan tiempos de ejecución de aproximadamente 230 segundos por generación y hasta cinco minutos en las primeras, ya que los individuos menos hábiles consumen el tiempo máximo. Se para la ejecución en la generación 300. Se comprueba la efectividad de una población en la figura 5.11 y la evolución de las puntuaciones en 5.12.

5.5. Capacidad del sistema con sonidos PCM

Los sonidos en este experimento son los mismos que en los anteriores pero en el formato PCM, en el que se alternan los valores muestreados en intensidad de cada canal. En la figura 5.10 se observa el sonido denominado *YZS* en ambos formatos, arriba el formato PCM y abajo el formato FFT, con los valores de intensidades en color para cada frecuencia, en un cierto momento.

Con una población de 200 individuos y 5 pruebas por individuo en cada generación, en una ejecución con dos sonidos simultáneos con formato tipo PCM se necesitan tiempos de ejecución de más de una hora por generación. En las primeras generaciones incluso se puede llegar a una hora y media, ya que los individuos menos hábiles consumen el tiempo máximo de la prueba. Esta cantidad de tiempo, mucho mayor que en sonidos de formato FFT, se debe al procesamiento del sonido añadido que se necesita. Los faros usan el sonido en formato PCM, y emiten en cada *quantum* de tiempo un paquete de sonido con 128 muestreos (el doble que el número de bandas de frecuencia) estéreo de 16 bits. Esos paquetes se retrasan de forma proporcional a la distancia entre emisor y receptor, dado que el sonido se propaga a una velocidad aproximada de 330 m/s, y se suministran a cada oído con ese retraso. Esto produce diferencias en lo percibido, en función del comportamiento del individuo.

A lo recibido por cada oído se le aplica la Transformada de Fourier (TF), y en este punto se igualan ambos métodos. Dado que se realiza este último paso, costoso computacionalmente, en cada ciclo de la simulación, ésta se vuelve tan lenta con este tipo de sonido. En cambio, si se aplica la TF antes de arrancar la simulación a cada sonido, se pierde la posibilidad de aplicar el retardo por distancia pero se gana en velocidad.

La conclusión que se puede sacar de este experimento es que el formato es ligeramente más difícil de manejar para tan pequeña red, ya que el resultado de la TF para la misma parte del sonido varía ligeramente por no incluir

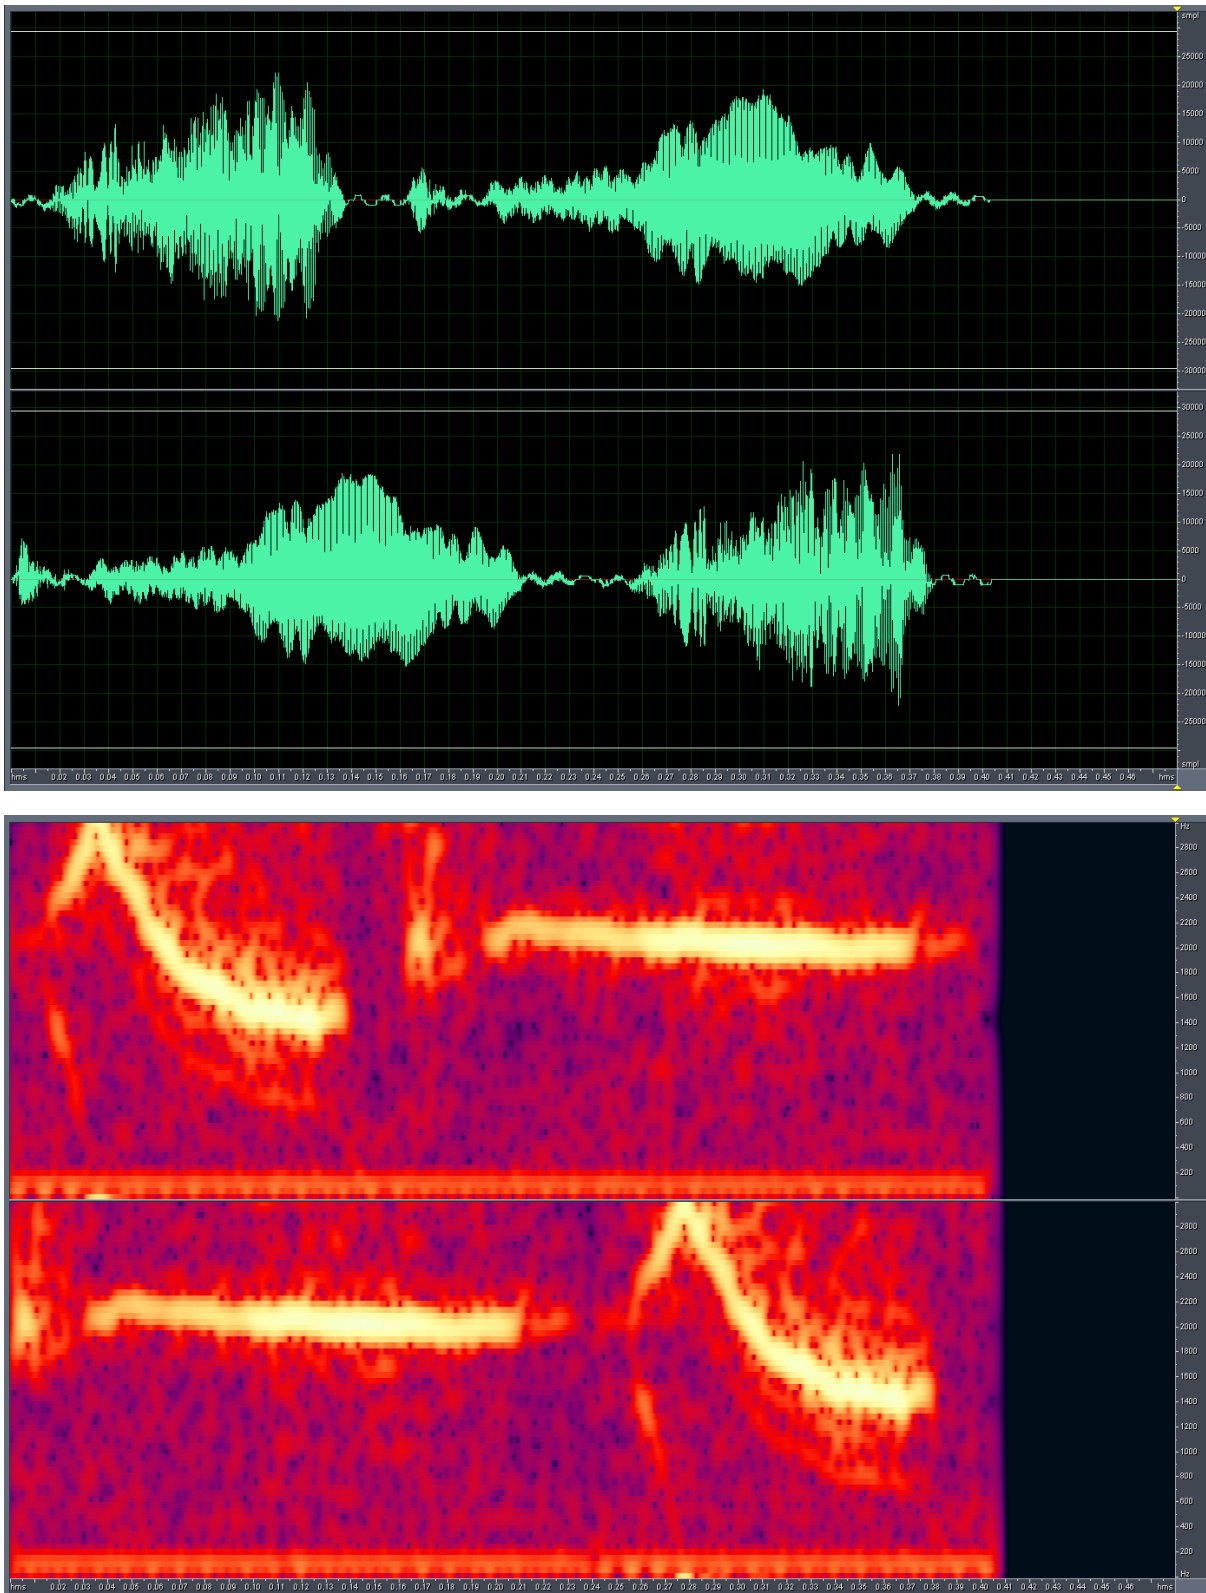


Figura 5.10: Intensidad y espectro de frecuencias de los sonidos usados en el experimento con partes de silencio, que son una modificación de los de la figura 5.5.




Figura 5.11: Histogramas para el experimento con dos sonidos con partes de silencio.

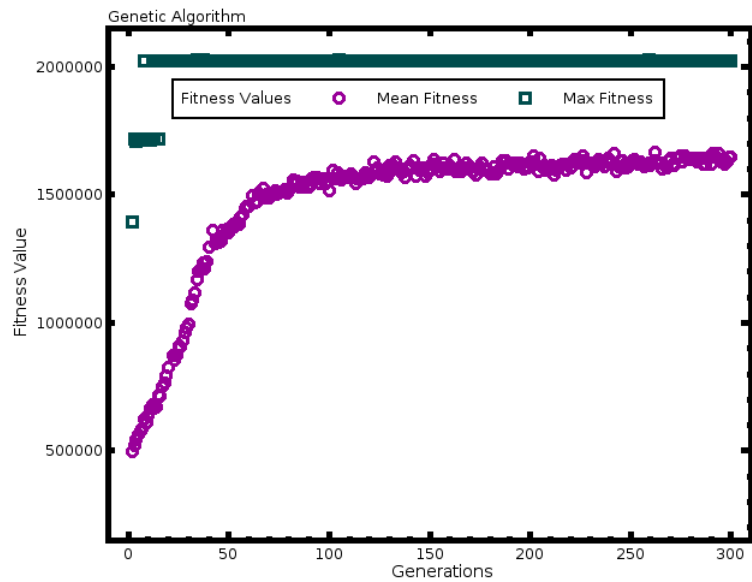


Figura 5.12: Diagrama de la evolución de la puntuación máxima y media de la población en el experimento con dos sonidos con partes de silencio.




Figura 5.13: Histogramas para el experimento con dos sonidos con formato PCM.




Figura 5.14: Diagrama de la evolución de la puntuación máxima y media de la población en el experimento con sonidos de formato PCM.

siempre exactamente los mismos muestreos. Sin embargo, produce un resultado satisfactorio que observa en la figura 5.13. La evolución genética se observa en la figura 5.14.

Análisis de un individuo

En este capítulo se describen las dificultades que conlleva analizar un individuo, un robot virtual producto de la selección artificial, y se lleva a cabo un proceso de “disección” del mejor individuo de una ejecución.

6.1. Objetivo y dificultades

El objetivo de analizar la estructura de un individuo resultante de la evolución para un problema concreto es conocer qué aprovechan los mecanismos evolutivos, con lo que es posible eliminar funcionalidades que no se necesitan para hacer la tarea y añadir nuevas características que la evolución puede explotar. Como consecuencia, el sistema va creciendo y es capaz de resolver más adecuadamente ese tipo de problemas.

Di Paolo (2002) subraya la dificultad de estudiar el resultado de la evolución en un sistema de Robótica Evolutiva:

“If one approaches Evolutionary Robotics with a scientific aim, for instance to model certain behaviours in natural creatures, or to test hypotheses about the nature of the mechanisms underlying certain kinds of behaviour, one is immediately confronted with the difficulty of analysis. This difficulty correlates precisely with the fact that the evolutionary algorithms work with a minimum of conceptual assumptions. Very rapidly the obtained results are complex enough that one must resort to neuro-ethological and psychophysical experiments on evolved robots to begin to understand what is going on; direct analysis of the controller is too difficult because cleanly divided, modular solutions are not found very often unless one constrains evolution to search for them. Studying evolved controllers is still easier than trying to understand the mechanisms of fully edged animal behaviour in the wild but, nevertheless, not a trivial task.” (Di Paolo, 2002)

Para analizar cómo trabaja y en qué se basa el reconocimiento tenemos por hacer un trabajo equivalente al de los neurobiólogos con los *C. elegans* y *Aplysia*, animales con el mismo papel en su caso que la *Drosophila* en la Genética.

Acorde a esto, el método más sencillo para analizar el funcionamiento interno de un individuo es el de la *ablación*, en el que se anula o destruye una parte de los elementos que lo componen, y se observa si se sigue llevando a cabo la tarea. De esta manera se elimina lo no necesario y se obtiene el conjunto mínimo de elementos, los que son suficientes para mantener el comportamiento. Eliminar combinaciones de elementos de un sistema para comprobar cuáles son necesarios en el comportamiento es un problema exponencial, ya que el conjunto de las partes (conjunto que contiene todos los subconjuntos posibles de un conjunto) es de 2^n . Sólo se simplifica si se encuentran módulos independientes, caso probable si el problema es fácil de solucionar pero casi imposible si el problema que solucionan los individuos es difícil.

En algunos campos de Redes Neuronales también se realizan estudios de simplificación de redes con mecanismos estadísticos llamados *poda* (en inglés, *pruning*). El objetivo de estos trabajos son la simplificación de una red totalmente conectada para mejorar la velocidad de ejecución en su uso y para facilitar la tarea de generalización cuando sufre de sobreconvergencia.

En este caso el mecanismo es simplemente un mecanismo de *prueba y error* hasta que se deduce la funcionalidad de cada una de las partes del robot. Se va probando a desactivar el disparo de ciertas neuronas, de forma que es equivalente a que la neurona no tenga ningún dato, puesto que todo se multiplica por cero. En esta situación se evalúa la capacidad del individuo “mutilado” para realizar la tarea. Se puede observar tres resultados cualitativamente diferentes: tener aproximadamente la misma capacidad, tener una notable bajada en la capacidad pero aun así seguir siendo capaz, y perder la capacidad equiparándose a un individuo generado aleatoriamente. El segundo comportamiento es el más interesante puesto que esas unidades eliminadas son el “ajuste fino” que permite ayudar a solucionar el problema en casos muy concretos en los que la solución general “se pierde”.

Con este trabajoso análisis se llega al individuo mínimo, sin partes no funcionales. En este punto se puede observar la dinámica de sensores, red neuronal y motores. Para ello es necesario encontrar una representación que sea fácil de analizar, ya que las mínimas variaciones son imperceptibles.

El analizar las capacidades de un individuo en concreto evita clasificar su comportamiento como el resultado aleatorio que se desvía hacia el resultado correcto, como si se consigue sacar cinco veces cara al tirar una moneda. Por ello, se analiza el mejor individuo de la generación 297 (de las últimas generaciones es el que da mejores resultados) del experimento detallado en la sección 5.4, probándolo 1000 veces para obtener los valores de efectividad eliminando “el factor suerte”. Consigue un total de 947 aciertos (por tanto el 95 %), 53 fallos (el 5 %) y en ninguna ocasión falla por no llegar a ningún faro, al consumir el tiempo máximo de 120 segundos o alejarse en exceso. La distancia máxima para parar la prueba es mayor en este caso que en las pruebas incluidas en el Algoritmo Genético, para dejar capacidad de recuperación.

6.2. Proceso

Se han eliminado varias combinaciones de neuronas y de sensores y se ha medido su eficiencia en cien pruebas. A partir de los datos del individuo (ver tablas 6.1 y 6.2) se empieza el análisis filtrando cada conexión. Como primer resultado se comprueba que usando sólo una neurona por lado (la 0 y la 5, por ejemplo) la eficiencia es nula. Las neuronas 2 y 3 son imprescindibles, ya que si se anulan y se funciona con todas las demás la capacidad también es cero.

Sensor	FC	Umbral	Anchura en bandas	Saturación	Peso
0	2292.9604	20	5	22	79
1	1391.715	23	15	269	52
2	402.98013	0	2	105	87
3	402.98013	0	2	105	87
4	1391.715	23	15	269	52
5	2292.9604	20	5	22	79

Tabla 6.1: Configuración de los sensores. Su separación a cada lado del eje es de 64° (grados sexagesimales).

Neurona receptora	Por la sinapsis	Peso	Retardo	Neurona fuente
0	0	0.128298	63	0
0	1	3.784749	41	1
0	2	4.762535	34	2
0	3	-0.267298	26	3
1	0	-2.86815	8	0
1	1	0.927321	56	1
1	2	4.1978526	44	2
1	3	3.1207504	28	3
2	0	-2.26485	55	5
2	1	8.52149	29	1
2	2	-0.188364	18	3
2	3	11.068664	0	3
3	0	-0.6081	18	5
3	1	0.751166	28	1
3	2	3.747914	0	3
3	3	0.289798	27	3
4	0	-2.86815	8	5
4	1	0.927321	56	4
4	2	4.1978526	44	3
4	3	3.1207504	28	2
5	0	0.128298	63	5
5	1	3.784749	41	4
5	2	4.762535	34	3
5	3	-0.267298	26	2

Tabla 6.2: Configuración y conectividad de las neuronas. Todas son efectoras y sólo la pareja 2–3 se conecta a ambos motores. Se puede observar que sólo se reescriben en las neuronas 2 y 3 los valores de las dendritas pares en la segunda vez que se expresa la información genética.

Con las parejas de neuronas 1–4 y 2–3 (es decir, eliminando la 0 y la 5) la eficiencia, tanto absoluta como relativa, es de un 58 %. Prácticamente la misma (62 %) si usamos las 0–5 y 2–3. Por tanto, son necesarias las parejas 1–4 y 0–5, que con ellas da un 90 %.

En cuanto a los sensores, en este caso son todos de peso positivo. Si eliminamos únicamente los sensores conectados a las neuronas 2 y 3 (sensores de peso 87) obtenemos una eficacia del 93 %, con lo que se confirma la suposición anterior, ya que no es necesario que tengan entrada para que estén continuamente disparándose. Si eliminamos sólo los sensores de las neuronas 0 y 5 (sensores de peso 79) la cantidad de aciertos ronda el 50 %.

En el caso de usar una única pareja de sensores, sólo en el caso de dejar los sensores de peso 52 (neuronas 1 y 4) conseguimos algún resultado (alrededor del 40 % de aciertos y 55 % de fallos). Esto puede indicar que aportan la función de *fonotaxia*, ya que con estos sensores y sus neuronas la eficiencia tiende al 50 % (ver segundo párrafo de esta subsección 6.2). Si usamos dos parejas de sensores, conseguimos un 3 % si eliminamos la pareja de sensores de peso 52 (a partir de ahora S52). Si eliminamos la de peso 79 seguimos en un 45 %, con lo que añadir a los S52 los S87 no aporta nada. Las parejas S79+S52 sí que dan un 93 %. Como conclusión, los S79 aportan la diferenciación entre los sonidos.

Si se elimina la parte del coseno en la función de disparo (ver sección 3.4.3) el rendimiento tiende al 50 %. En




Figura 6.1: El espectro de frecuencias de los sonidos usados en este experimento (ver sección 5.4), filtrados tal como lo hacen los sensores (frecuencias alrededor de los 2293 Hz y 1392 Hz), con dos diferentes intensidades de color en la representación de la intensidad con el objetivo de observar por una parte el ruido y por otra la intensidad de la señal que usa el individuo.

este caso la pendiente de caída de la exponencial es muy suave. Si se modifica haciéndola más suave el rendimiento es similar y se mantiene la fonotaxia, es decir, sólo un 14 % se “pierden” y no llegan a ningún faro. En el caso de hacer mucho más fuerte la caída de la exponencial, ningún individuo consigue llegar a uno de los faros.

Si la función es simplemente la constante cero (luego la función es un pulso, porque se ponen a uno los tres primeros valores) el resultado es parecido a la caída suave de la exponencial, con un 15 % de “deambulantes”, 34 % de aciertos y 51 % de fallos.

Haciendo la función $f = 1$ el individuo nunca llega a ningún faro. Sin embargo, al usar el valor 0,5 en la función excepto en los tres primeros valores, el comportamiento es el mismo que si se usa el 0.

En el caso de usar la parte coseno con la mitad de intensidad el resultado es de un 90 % de aciertos. Se consigue menor rendimiento con una exponencial que cruza el eje horizontal a medio camino (79 % de aciertos) y con la función no continua con valor 1 en los primeros 16 tics y $-0,25$ en los 16 últimos (65 % de aciertos). Si el punto de corte se pone en el tic 12 y en el tic 10 se obtienen rendimientos parecidos, que se pierden por completo al colocarlo en el tic 8. La conclusión es que se necesita una función equivalente que introduzca valores negativos a partir de un cierto punto, con la intención de inhibir el disparo.

Todo esto queda más fácil si sólo se usa la parte coseno de la fórmula original, y se varía el coeficiente que encoge o alarga la senoide. Con el valor original de 2,5 la eficacia es del 80 % y con 2,65 es del 65 %. Con 1 es del 69 % y con 1,5 el 77 %. Como se ve el rendimiento se degrada suavemente hasta la total incapacidad de realizar la tarea con 0,85 o menos y con 2,7 o más, valores con los que los individuos casi nunca llegan a alguno de los faros.

En resumen, las neuronas se deben disparar a cierto ritmo, aprovechando su dinámica interna, para reconocer un determinado ritmo en el sonido.

Si se anula la comunicación entre neuronas a través de los axones, la efectividad es del 50 %, por lo que se comprueba que son necesarios para distinguir los sonidos. Si se prueba a activar los axones que recibe cada pareja de neuronas, los resultados obtenidos no permiten hacer ninguna conclusión. Al tener en cuenta sólo los axones que reciben las neuronas 0, 1, 4 y 5 se obtiene el 90 %, por lo que otra vez se determina que el único propósito de las neuronas 2 y 3 es el del movimiento.

Con los axones la técnica es ir *desenchufándolos* hasta que deje de funcionar. De esta forma se selecciona el mínimo conjunto de axones necesarios para mantener la funcionalidad. De todas formas, la eficacia baja desde el 90 % hasta el 75 % cuando se desconectan los axones de peso 34, por lo que axones desconectados no transmiten información o simplemente ruido necesario y por ello se puede desestabilizar la red.

Como resumen, se pueden comparar los esquemas de la estructura del sistema de control del robot virtual antes y después (fig. 6.2) de la eliminación de lo innecesario o que casi no afecta a su rendimiento.

La teoría que se puede plantear es que el sensor de peso 52 activa las neuronas 1 y 4, que inhiben a través del axón de retardo 8 y peso $-2,8$ a las neuronas 0 y 5. Todas las neuronas anteriores son neuronas motoras, es decir, activan los motores. Cuando el sensor de peso 52 recibe por la frecuencia de 1391 Hz la señal adecuada, se dispara con la adecuada realimentación configurada con un retardo de 56 y peso $0,93$, que inhibe una de las neuronas motoras de su lado (la 0 o la 5) y permite girar.

Cuando se pasa a analizar el tema de los retardos entre los axones o conexiones entre neuronas, se tiene como eficacia de partida es el 90 %. A todos los valores de retardo se les suma un mínimo de valor 4. En esta situación si a todos se les asigna el valor cero que equivale a la propagación instantánea de la perturbación, el rendimiento es nulo tanto absoluta como relativamente.




Figura 6.2: Estructura del individuo del análisis, antes y después de la poda. Los números grandes son el número de neurona, y los pequeños indican el retardo de las conexiones que llegan a esa neurona. El color naranja expresa que el peso es positivo, y el azul que es negativo. En el caso de los sensores, todos son positivos (color vino).

El análisis sigue poniendo a 0 uno de los tres retardos que se ven en la parte de abajo en la figura 6.2 se obtiene una pequeña bajada de un 10 % y la eficacia ronda el 80 %, sea cual sea el elegido. Si lo que se hace es eliminar todos los retardos menos uno, la capacidad del individuo para solucionar el problema se acerca a un comportamiento aleatorio. Si se dejan en 0 todos los retardos menos el de valor 56 se obtiene una eficiencia del 60 %. De la misma forma, usando solamente el retardo de valor 34, la eficiencia es 67 %. Si se anulan todos los retardos menos el de valor 8 la eficiencia es 0.

Una cuestión interesante es que el sistema probablemente usará la solución más sencilla para el problema, que en este caso sólo requiere una conexión recursiva en las neuronas 1 y 4. Con sonidos y entrenamientos más variados, con desarrollo *ontogenético* la estructura que se puede obtener es previsiblemente compleja.

En el apéndice A se puede observar el conjunto de datos extraído de una prueba del individuo analizado.

Parte IV

Conclusiones y trabajo futuro

Resultados globales, conclusiones y trabajo futuro

Este trabajo ha producido publicaciones en diferentes líneas de investigación, como consecuencia de la visión multidisciplinar del mismo, que incluye la Inteligencia Computacional, la Vida Artificial y la Filosofía entre otras para el desarrollo de un comportamiento de navegación en un robot virtual bioinspirado mediante la extracción de características temporales de sonidos reales. Las aportaciones han sido publicadas en el congreso sobre Vida Artificial *Alife X* celebrado en Bloomington (Indiana, EE.UU.) (González-Nalda y Cases, 2006a), en el congreso que celebraba los 50 años de la Inteligencia Artificial en Albacete (González-Nalda y Cases, 2006b), y en la revista *Neurocomputing* (González-Nalda y Cases, 2008).

Se presentan las conclusiones y consecuencias en la disciplina, las líneas de trabajo futuro y vías que sugiere como campos de desarrollo.

7.1. Objetivos y resultados

Esta memoria describe las consideraciones usadas para desarrollar el sistema TOPOS, que están conformadas por una visión histórica de la Robótica y su relación con la Inteligencia Artificial, y por un análisis del estado del arte de la Robótica Evolutiva (capítulos 2 y 3). Tras este repaso a la situación de la disciplina se expone el diseño de la aplicación TOPOS y las pruebas realizadas para comprobar sus capacidades y como consecuencia la validez del planteamiento y el cumplimiento de los objetivos (capítulos 4 y 5). En el capítulo 6 se analiza la estructura de un individuo para observar cómo realiza la tarea.

La aplicación TOPOS permite cumplir los objetivos de esta tesis de la siguiente forma:

7.1.1. El problema conlleva un desarrollo técnico encuadrado en la Robótica Evolutiva

El sistema TOPOS está diseñado para que se puedan cumplir los objetivos definidos en la sección 1.2. De hecho, el objetivo primario de este trabajo es obtener un robot que realice correctamente la tarea de navegación en entornos no estructurados, para la que está diseñada esta aplicación.

El sistema TOPOS se sitúa a medio camino entre el paradigma ingenieril y el biomimético. Se busca aprovechar el pragmatismo de la ingeniería y la inspiración biológica de las nuevas líneas de investigación en la moderna disciplina de la biomimética al unir las ventajas y eliminar los inconvenientes. Como resultado, el robot realiza la tarea con gran acierto pese a la dificultad del problema para tan pequeña estructura, como se puede observar en la figura 6.2.

El robot simulado en el modelo es capaz de moverse hacia un punto del espacio sin tener información de en qué punto se encuentra. Solamente puede reaccionar a ciertas intensidades de sonido y en determinadas frecuencias para alcanzar una de las fuentes de sonido. También necesita aprovechar la forma de su cuerpo y la posición en el espacio, es decir, necesita estar corporeizado y ubicado. Las capacidades son inseparables de un cuerpo que existe en un lugar, y el modelo del mundo que maneja el robot es el propio mundo.

La obtención de este robot genérico y virtual marca como condiciones o causas suficientes las técnicas y los análisis científicos y filosóficos usados, o expresado de otra manera, un robot funcional valida los planteamientos teóricos y técnicos para llevar a cabo un desarrollo técnico en el campo de la Robótica, y especialmente en cuando se trabaja en entornos no estructurados. Las técnicas y análisis se han elegido por su alto grado de inspiración en los seres vivos, pero se han adaptado para mantener el sistema tan sencillo como sea posible. La sencillez facilita el diseño, la simulación y el análisis del sistema. Es un prototipo que afirma la viabilidad de sistemas posteriores. Se evita abordar problemas como los relativos al paso entre la simulación y la parte física del robot, por ser solamente un primer paso hacia la solución de un problema real y porque este tema podría facilitarse de forma clara con un mecanismo de *morfogénesis* que se plantea como trabajo futuro.

Como cuestión concreta que se puede resaltar es la validez del uso de Algoritmos Genéticos para la búsqueda de una configuración adecuada en cuanto a parámetros y coeficientes de la Red Neuronal y los sensores. La base de la Robótica Evolutiva queda comprobada como un sistema de desarrollo de robots.

El robot exhibe comportamientos supuestamente más complejos que lo que se pudiera pensar para sistemas de control simples. Sin embargo, se puede observar un paralelismo con los seres vivos en cuanto a estructura y capacidades.

Este trabajo de Robótica Evolutiva se sitúa en un punto intermedio entre los modelos abstractos de *Neurociencias* y el uso de redes neuronales como sistemas de aprendizaje automático para el control de robots en los que la red neuronal es simplemente un mecanismo de generalización sin significado biológico.

Se pueden observar claras diferencias de planteamiento si se compara con el trabajo de Lund et al. (1997) (ver el apartado 3.3.9), en el que el principal objetivo es la comprobación de teorías *neuroetológicas*. Sin embargo, no se cierran las vías de estudio de la Robótica Evolutiva en los campos cognitivo y biológico por trabajar en la vía técnica. Simplemente en este trabajo no se realiza un análisis de ese tipo, aunque en este punto sí que se puede afirmar que el sistema obtiene robots que distinguen sonidos y reaccionan con una *fontaxia*, es decir, tienen una clara capacidad cognitiva. Si bien no se analizan filosóficamente estos comportamientos, sí que se ha querido facilitar su estudio incluyendo en el sistema partes biológicamente inspiradas, sin llegar pero acercándose a una simulación de la dinámica de sus homólogos en los seres vivos. Por este motivo hay una clara posibilidad de analizar este sistema desde un punto de vista filosófico, como se indica en la sección 3.8. Este sistema es un

modelo funcional que permite plantear una teoría de la percepción, sin llegar a un modelo mecanicista como el de Lund, Webb y Hallam (1997). Es factible entonces hacer con este modelo trabajos de tipo *epistémico*, que pueden proporcionar información para establecer teorías sobre la percepción y la navegación en seres vivos. En el capítulo 6, en el que se analiza un individuo, se pueden ver los resultados de la selección artificial que permite a un ser definido por unos cuantos parámetros actuar de forma correcta con un sistema perceptivo que extrae la información necesaria de su entorno.

7.1.2. Trabajo sobre algunos problemas de la Robótica Evolutiva

Al buscar un esquema que haga viable el desarrollo de robots autónomos como el descrito anteriormente, es necesario afrontar ciertos problemas técnicos de la Robótica Evolutiva como los planteados al elegir el problema principal que se quiere resolver. Los problemas técnicos surgidos en este caso es principalmente el reconocimiento de señal temporal multidimensional y de estructura compleja, variable en el tiempo, multidimensional, que varía independientemente del comportamiento del individuo, que se divide en el uso de sonidos como puntos de referencia para la navegación, la flexibilidad de los sensores para diferentes intensidades de señal, el filtrado para la extracción de características y el cambio de la señal de forma independiente al movimiento del robot. Estos puntos se abordan en el presente trabajo con el problema planteado y se resuelven satisfactoriamente. En la disciplina de la Robótica Evolutiva no se habían tratado problemas de tal complejidad hasta el presente, debido principalmente a las características temporales del sonido reconocido, al cambio de la señal de manera independiente del movimiento del robot y a la falta de direccionalidad de la recepción de la señal.

El robot navega usando y reconociendo dos sonidos como puntos de referencia. Es un sistema básico de navegación, pero lo suficiente para plantearse en extrapolar su viabilidad a más señales y tareas aunque se compliquen de forma incremental. Para reconocer este tipo de señales (en concreto sonido real) como puntos de referencia, el modelo se basa en una red neuronal de pulsos. Esta red neuronal permite hacer la tarea y queda aún por determinar su capacidad en otras tareas cuantitativa y cualitativamente más complejas, a pesar de los estudios teóricos ya realizados. Una parte de la capacidad es la adaptación de la red neuronal a los sensores que resultan de la evolución, y que seleccionan la parte de señal que puede procesar la red neuronal. En cuanto a la evolución de estos sensores para el procesamiento de señal con dichas características de complejidad, se define una forma de sensor parametrizada (y por tanto evolucionable), de forma que se pueden seleccionar diferentes componentes del sonido, frecuencias que activan ciertas neuronas que a su vez aceleran o frenan los motores. Los sensores deben activarse aunque la señal varíe en intensidad por la distancia del estímulo. El robot no sólo discrimina la señal, sino que produce un movimiento para acercarse a una de las fuentes, paso básico en la navegación.

Es importante señalar que el individuo es un todo, y que su estructura es independiente del tipo o forma de sonido que se use (voz, ruidos, música. . .). No se añade ningún tipo de conocimiento para ayudar en la tarea, y la tarea de reconocimiento de patrones se realiza simultáneamente a la parte sensorial.

El sistema demuestra que es escalable hasta problemas que se perciben como muy difíciles para el planteamiento. Sin embargo, es necesario plantearse la necesidad de ampliar los diseños cuantitativamente para encontrar los límites. El problema de navegación mediante reconocimiento de puntos de referencia auditivos es lo suficientemente difícil como para encontrar y marcar cuál es el límite del esquema y cómo es de escalable, ya que problemas más difíciles requieren mejores aproximaciones.

7.2. Conclusiones y trabajo futuro

El trabajo descrito en esta memoria cumple los objetivos de abrir camino en una disciplina que podría haberse considerado con poco futuro en cuanto a su utilidad técnica e ingenieril. Estos resultados indican que es posible usar estas técnicas en la robótica de entornos no estructurados, aunque sea todavía necesario mucho trabajo para desarrollar un robot de este tipo que pueda llevar a cabo tareas útiles en situaciones en las que no se puede usar mapas. En cuanto a su valor **epistémico**, se proporciona nuevo material analizable, que si bien resulta dificultoso, no supera (ni siquiera se acerca) a lo habitual en el estudio de las capacidades cognitivas de los seres vivos. En este caso los experimentos son repetibles y las variables se registran fácilmente.

De la misma forma que el aprendizaje por parte de una persona de la parte básica de un área del conocimiento produce nuevas preguntas que conducen a aprender más, esta memoria más que responder señala nuevas líneas de trabajo dentro de la disciplina, indicando los puntos fuertes y débiles. Por ejemplo, pone de manifiesto carencias habituales en las técnicas de la Robótica Evolutiva, que dificultan gravemente la tarea o la generalización de objetivos y problemas. Estos obstáculos resultan casi inevitables, como la sobreconvergencia de los Algoritmos Genéticos (ver la sección 3.2). Por la sobreconvergencia, los robots aprenden *demasiado* y pierden la capacidad de generalizar y reconocer otros sonidos parecidos a los aprendidos. Se podría resolver esto generando un conjunto de entrenamiento de varias parejas de sonidos, pero esto requeriría un tiempo de ejecución mucho más largo (se discutirá más tarde en torno al tema de la morfogénesis). Un conjunto de sonidos de prueba permitiría detectar las características de los sonidos que se usan para discriminarlos. Además, en el caso de que los puntos de referencia no fueran únicos sería posible que, en un entorno continuo que puede ser percibido, se reaccionara más fácilmente a ciertas zonas que tengan unas determinadas características, que se acoplan mejor al sistema perceptivo y que aumenta la cantidad de información que dan en comparación con otros puntos del espacio.

Un problema de este modelo es que los robots aprenden a reconocer los sonidos que se indican al principio de una ejecución, y que esto dista mucho de la forma de aprendizaje que tiene un animal. Durante el tiempo de vida van aprendiendo diferentes respuestas a estímulos en función de múltiples variables, lo que permite una adaptación al entorno mayor a la puramente instintiva (el llamado efecto Baldwin). Por tanto, sería deseable que el robot pudiera adaptarse con mecanismos como los condicionamientos, muy estudiados en Psicología.

Aparte de la **corporeidad** y **ubicación**, más adelante y con problemas cuantitativamente mayores y por ello más difíciles, sería quizás necesario un estado interno del robot y propioceptores (posición interna del individuo) e interoceptores (información de los órganos) para actuar en función de las necesidades, ya que los estímulos no sólo son externos, sino que los estímulos se pueden recibir en el sistema **interoceptivo**, en el **propioceptivo** y en el **exteroceptivo**. La cantidad de energía restante en el robot, las inercias, y otras percepciones facilitarían realizar mejor mayor número de tareas.

En aplicaciones robóticas el ruido de motor y los sonidos de fondo tienen un fuerte impacto en el reconocimiento auditivo. En este trabajo se muestra que estos ruidos de fondo tienen relativamente poco impacto en la navegación mediante el reconocimiento de sonidos. El ruido de los motores del robot mejoraría la navegación, puesto que esto es una manera sencilla de implementar la propiocepción. Éste es un interesante tema que requiere tiempo y una cuidadosa investigación, debido a que debe probarse que la propiocepción mejora las capacidades de navegación. De la misma forma, añadir defectos a los sensores y motores permitirían comprobar la robustez del sistema más allá de la capacidad de funcionar con ruido en la señal.

Dos puntos con los que se puede trabajar en desarrollos posteriores del sistema son, por una parte, los costes computacionales de las pruebas (debido a la complejidad de la simulación) durante la ejecución del algoritmo genético; por otra parte, la **morfogénesis** o la dificultad de obtener tan compleja estructura más que en la variación

de parámetros (y poder variar, por ejemplo, la forma del robot), y quizás la necesidad de una expresión no lineal de la información codificada en el genoma. Ambos son la clave de la escalabilidad, el gran problema de la Robótica Evolutiva. Este problema se solucionaría con un sistema de morfogénesis que no es posible con el modelo actual. La morfogénesis influye sobre la complejidad de la simulación y por tanto determina el coste computacional. Pese a esto, y teniendo en cuenta el aumento de las capacidades computacionales de las nuevas generaciones de ordenadores y las posibilidades de paralelismo que permite el sistema, el problema clave es crear los complejos mecanismos de morfogénesis necesarios para añadir *biodiversidad* a la población que evolucionamos, con una mejor expresividad de mayores redes neuronales (que permitan comportamientos complejos) en la información genética, mayor capacidad para dar *corporeidad* a los individuos (con más sensores y más repartidos por todo el robot), y mayor flexibilidad y escalabilidad en la evolución. Además se debe incluir un tiempo de aprendizaje de la red neuronal que permite una adaptabilidad adquirida durante los primeros estadios de vida de los seres vivos, capacidad que no puede dar la adaptación *filogenética*. También puede ser muy interesante la mezcla de diferentes tipos de neuronas en una misma red neuronal, como sugieren algunos estudios de *Neurobiología*.

La información que describe el individuo no debe ser de muy gran tamaño, que impediría una aplicación razonable de los algoritmos genéticos. Una pequeña cantidad de información, junto con técnicas no lineales de *morfogénesis* (a su vez paramerizada en la información genética) y procedimientos extraídos de la observación de los seres vivos, puede dar lugar a sistemas en los que desarrollar complejos comportamientos. La descripción exhaustiva de cada una de las neuronas y sus conexiones debe dar paso a mecanismos que generen grandes redes, como los descritos por Kwok, Jurica, Raffone y van Leeuwen (2007) y que apliquen simulaciones de distintos tipos de neuronas, como las desarrolladas en el trabajo de Izhikevich (2003, 2004, 2006). Este modelo neuronal permite simular fielmente la dinámica de neuronas biológicas con poco coste y una gran flexibilidad, lo que permite aumentar el número de neuronas. De esta forma las neuronas funcionan como método de búsqueda de correlaciones entre las diferentes partes de la entrada y como método de generación de movimiento mediante la activación de mayor cantidad de neuronas efectoras. Probablemente el aumento de señales de entrada por la unión de sistemas *interoceptivo*, *propioceptivo* y *exteroceptivo* provocará una rica dinámica en la red neuronal.

Las neuronas de pulsos facilitan ese análisis de correlaciones por permitir usar aprendizaje *hebbiano* de una forma coherente. En un modelo con gran cantidad de neuronas y adaptación *ontogenética* al entorno el uso de las neuronas de pulsos puede ser mucho más útil. Por esto se indica como camino de trabajo la ampliación del modelo de la forma descrita.

Todo lo expuesto no tendría sentido en un entorno relativamente simple, por lo que es necesario un sistema de simulación que permita un entorno continuo y variado, complejo, en el que la extracción de características proporcione todas las ventajas para realizar tareas más acordes con las características del entorno.

7.2.1. Comparación con sistemas basados en visión

Si se compara el sistema de Suzuki (2007) (descrito en el apartado 3.3.3) con TOPOS, objeto de la presente memoria, se puede decir que hay varias diferencias y coincidencias. Son sistemas comparables porque ambos son trabajos en Robótica Evolutiva y abordan problemas de procesamiento de señal con una perspectiva *conexionista*. En concreto el estudio de ambos se centra en las características temporales de la señal como información necesaria para la navegación con puntos de referencia.

La diferencia evidente es el tipo de señal que se usa en cada caso, imagen en el caso de Suzuki (2007) y sonido en el de TOPOS. Sin embargo, ambas son análogas si el sonido es constante en ausencia de movimiento del robot y su recepción direccional. En TOPOS el ángulo de incidencia del sonido en el oído externo atenúa la intensidad del

sonido de forma proporcional (ver el apartado 4.1.2.1). La intensidad del sonido también decrece con la distancia, inconveniente del que carece la visión en el experimento de Suzuki por tratar con cuadrados negros cuyo cambio de tamaño no impide su detección inequívoca. Sólo en el caso de TOPOS el sonido varía independientemente del movimiento del robot, ya que si éste está quieto el sonido cambia (a excepción del ruido tanto blanco como rosa).

Otra diferencia es lo que se podría denominar forma de la señal. En el caso del reconocimiento de los cuadrados negros hay dos intensidades de señal mientras que en el sonido tiene diferentes intensidades en la propia señal, aparte de la atenuación por distancia o ángulo. En el caso del sonido, además la intensidad también varía en función del tiempo. Esto sería equivalente a que cada cuadrado negro se convirtiera en una fuente de luz compuesta por bombillas roja, verde y azul que fueran combinándose para cubrir una secuencia de colores, como ocurre con un píxel o punto de una pantalla.

Si se atiende a la forma del robot, en el caso de la visión hay un grupo de sensores con una estructura espacial, mientras que en TOPOS hay dos lados en los que se agrupan los sensores de forma simétrica, por lo que los robots están obligados a reaccionar de la misma forma que los vehículos de Braitenberg (ver la sección 2.9.4). Serían más parecidos en el caso de que el ángulo de separación de oídos con respecto al eje fuera cero, con lo que las dos *orejas* estarían orientadas hacia adelante.

La estructura de las redes neuronales es diferente, principalmente por las diferentes capas del sistema de visión y por la estructura simétrica y uniformemente recurrente de la red de TOPOS y por supuesto por el tipo de neuronas *sigmoideas* y de pulsos, respectivamente. Las neuronas de pulsos (ver el apartado 3.4.3) se disparan de forma digital, es decir, se disparan o no se disparan, con lo que la codificación de tiempos es más precisa pero dificulta la de intensidades, en las que las *sigmoideas* pueden trabajar mejor. Conforme los entornos de simulación y los sensores mejoren, el rendimiento de las Redes Neuronales de Pulsos será mayor.

En cuanto a la función de adecuación, en el trabajo de Suzuki se va evaluando durante la prueba ya que usa la velocidad en cada momento de la misma, mientras que en TOPOS sólo se tiene en cuenta la distancia mínima a cada uno de los faros. Sin embargo, en el presente trabajo se evalúan los comportamientos no sólo por la función de adecuación sino también por un método de evaluación absoluto representado con las variables EFA y EFR (ver el apartado 4.1.6). El significado de la primera es el número de aciertos frente al número de pruebas en porcentaje. EFR es la proporción entre aciertos y fallos. Este tipo de evaluación permite observar la capacidad de la élite de la población, como una medida estadística más completa, informativa y fácil de interpretar que el valor relativo de la media de los valores de adecuación o *fitness*.

7.2.2. Otras ramas modernas de la Robótica

Aún más reciente que la Robótica Evolutiva se puede encontrar la Robótica Epigenética o Robótica del Desarrollo (*Developmental Robotics* o DevRob, también llamada EpiRob). Esta línea de investigación plantea el estudio del desarrollo y cambio del comportamiento del individuo en relación con su entorno, es decir, su evolución *ontogenética*, que se ajusta perfectamente a las líneas de trabajo futuro planteadas, tanto la *morfogénesis* como el estudio de la flexibilidad de los nuevos modelos de redes neuronales para el aprendizaje. Esta perspectiva permitiría *esquivar* problemas como la citada sobreconvergencia de los algoritmos genéticos.

Es especialmente interesante la unión de las técnicas de ambas Robóticas para el ajuste de los mecanismos adaptativos de la Robótica del Desarrollo con los genéticos de la Robótica Evolutiva.

Ante esta estimulante situación de la Robótica, lo último que se puede pensar es que está todo hecho.

Parte V

Apéndices, bibliografía e índices

Gráficas del análisis de un individuo

Las figuras [A.1](#), [A.2](#) y [A.3](#) contienen los datos de una prueba en la que el individuo trabaja correctamente. Se representan las coordenadas, las entradas y salidas de los sensores, la velocidad de disparo de las neuronas y la activación de los sensores. En la gráfica que enfrenta la coordenada x con la y se observa la trayectoria del individuo con un característico giro que hace hacia ambos lados (él mismo es simétrico) en función de dónde se encuentre el faro correcto. Debido a la parte aleatoria en la activación de los sensores se genera un movimiento parecido al *browniano*, lo que facilita los cambios de dirección al desacoplar el entorno del individuo. En estas gráficas se usan variables que permiten ver el comportamiento de sensores y neuronas. En el caso de los primeros se representa el inverso del tiempo desde el último disparo. Para ello se resta dicho tiempo de la duración de un disparo, que en estos experimentos es 32. En cuanto a las neuronas, el valor d es parecido por tener en cuenta el tiempo, pero resta del valor 32 el tiempo transcurrido desde el penúltimo disparo. El valor distinto de cero indica además que la neurona se ha disparado.

En el caso de los motores, el valor representa el tiempo que hace que se ha disparado por penúltima vez la neurona motora. Así pues, cada una de las gráficas numeradas como motores muestran el tiempo pasado desde el último disparo de una de las neuronas. Por ejemplo, $m1$ muestra el tiempo transcurrido desde que la neurona número 1 se disparara. Las líneas rectas ascendentes de puntos indican el paso del tiempo sin un nuevo disparo. Para hallar la activación del motor se hace la media de los tiempos por cada neurona motora y, obviamente, cuanto más baja la media más velocidad en el motor.

Las figuras [A.4](#), [A.5](#) y [A.6](#) muestran parte de la actividad reflejada en las anteriores, alrededor del instante de tiempo 92.600, en el que se desvía inicialmente hacia la fuente correcta, lo que probablemente facilitará el desvío final hacia la misma. En concreto se puede observar la variable ángulo en la [A.4](#), el sensor $s0$ en la [A.5](#) y el motor 0 en la [A.6](#) en los instantes 92600 y 94200, en los que gira hacia la derecha. En todas estas gráficas se ve la comunicación entre la activación del sensor y su disparo, y el disparo de la neurona y un aumento en la




Figura A.1: Gráficos de las coordenadas, distancias y ángulo analizados durante una prueba desde el punto de salida hasta llegar a la fuente correcta. Los valores x e y son las coordenadas absolutas, $d1$ la distancia al faro correcto y $d2$ al erróneo. El ángulo inicial de 180 indica que se dirige hacia la izquierda. Si se da un giro de 180 a la gráfica X-Y se obtiene la trayectoria real, en la que lo correcto es el giro hacia abajo o a la izquierda, ya que la coordenada Y crece hacia abajo.

velocidad del motor (la gráfica del motor es inversa, los picos hacia abajo son aumento de velocidad). Esto da un resultado interesante, que consiste en la idea de que el individuo detecta lo que debe evitar, y se observa en la correlación entre disparo de un sensor y giro hacia el lado contrario al del propio sensor. Por tanto, hay una *fonotaxia* positiva por el peso negativo de la señal que recibe la neurona 1 desde la 0 con un retardo 8 (y de forma equivalente en el lado derecho), y una fonotaxia negativa selectiva con el juego de retardos en los axones de peso positivo en las neuronas 1 y 4.

Las figuras A.7, A.8 y A.9 también muestran parte de los datos alrededor del instante de tiempo 120,000, en el que se desvía definitivamente hacia la fuente correcta.

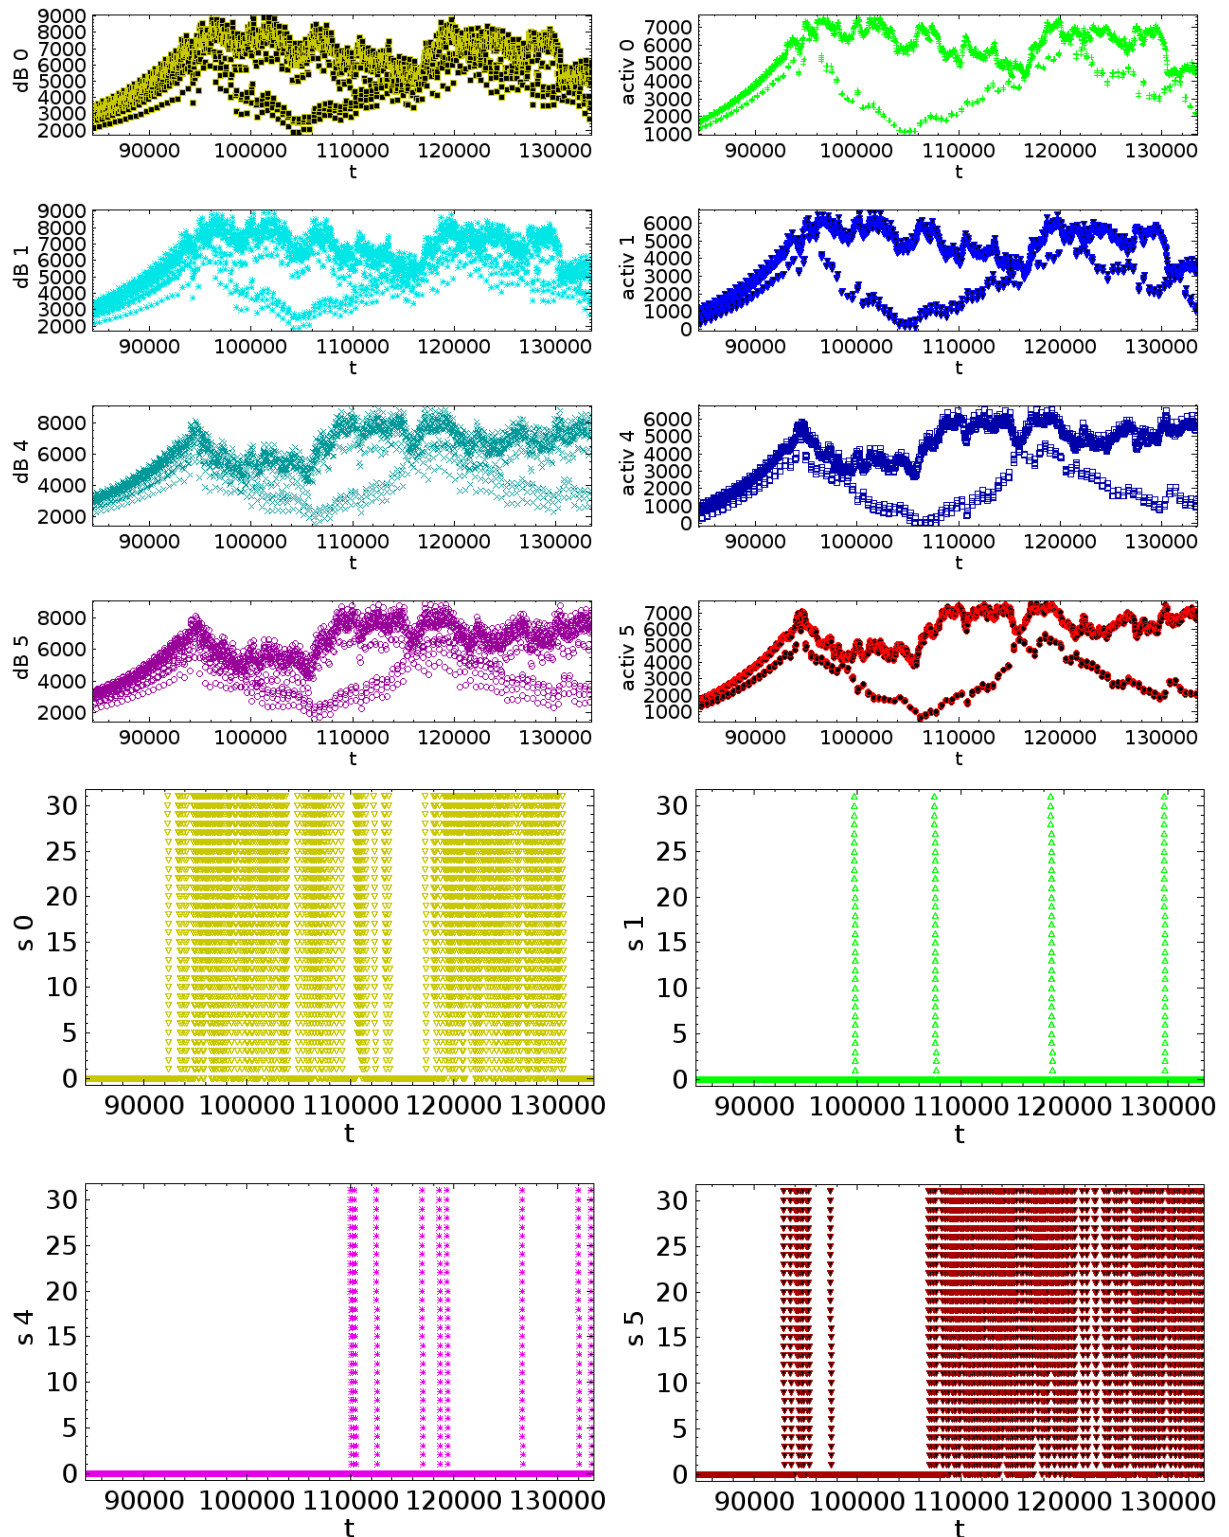


Figura A.2: Gráficos de valores de cada uno de los sensores analizados durante una prueba desde el punto de salida hasta llegar a la fuente correcta. El valor dB es la intensidad del sonido que entra al sensor y $activ$ es la respuesta de éste, que causa la salida s .

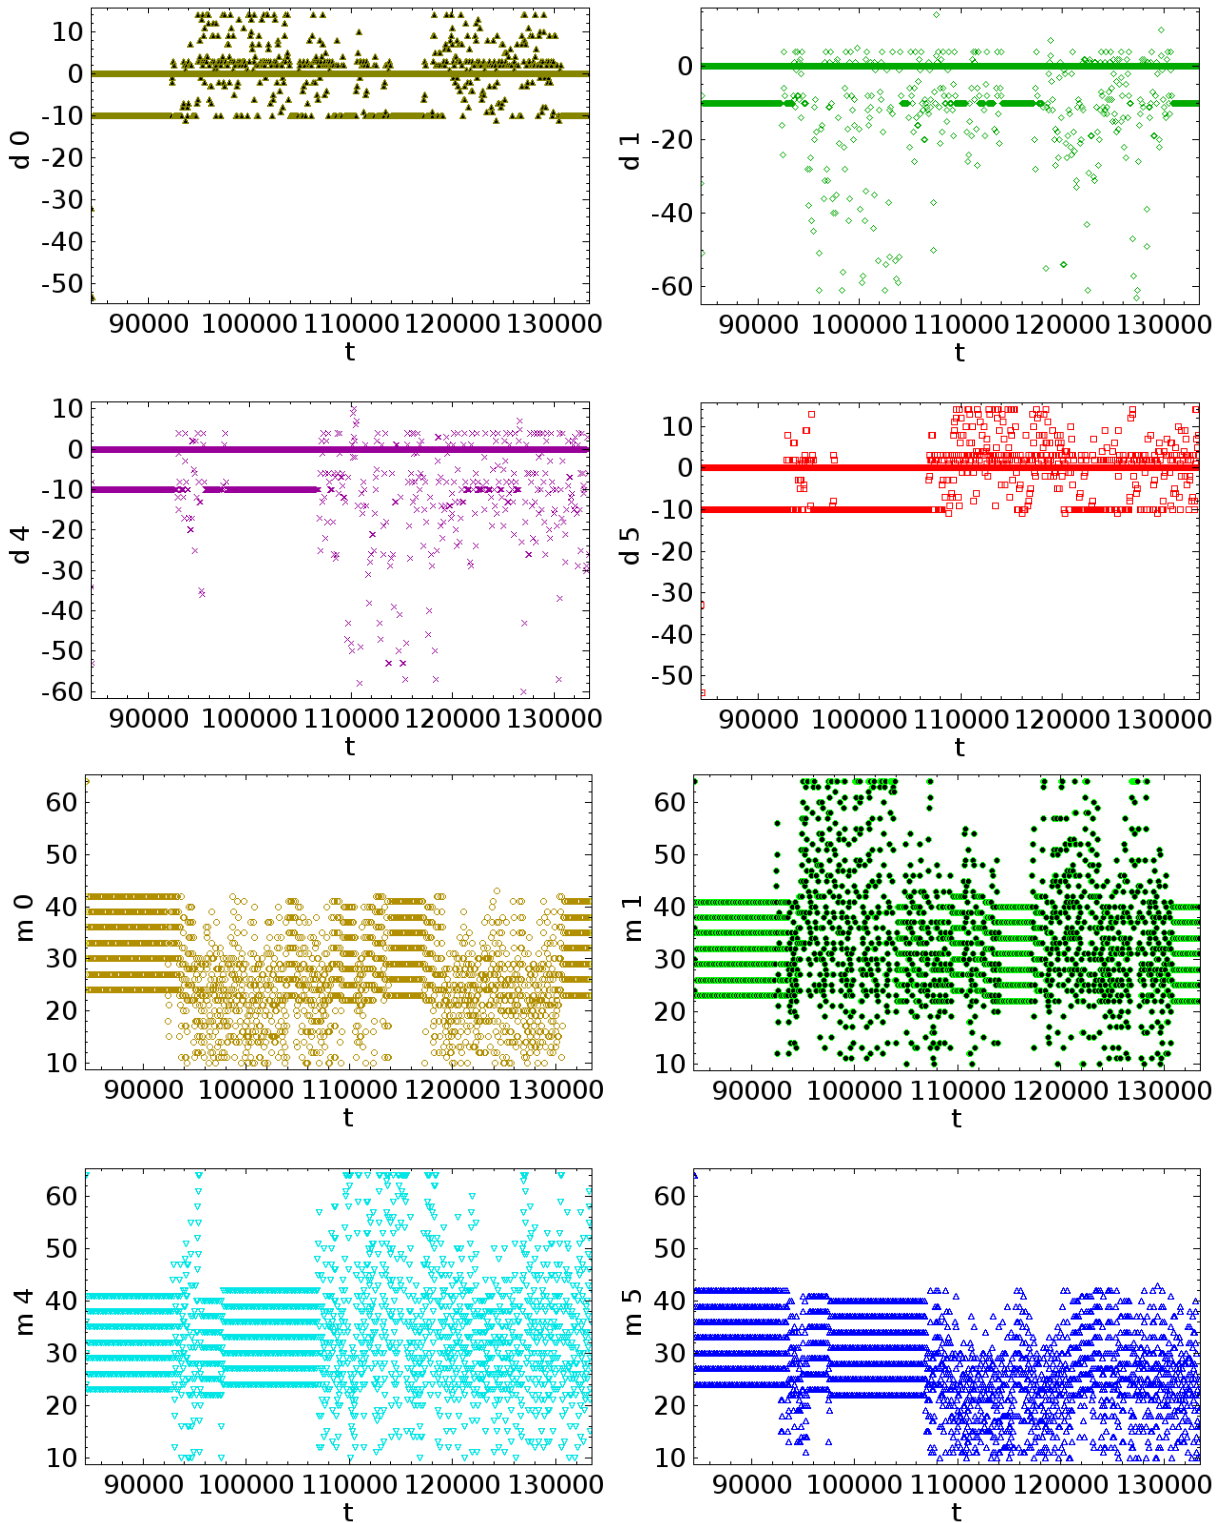


Figura A.3: Gráficos de valores de velocidad de disparo de la neurona (el valor d , cuanto más alto más rápidamente) y de la activación de los motores (m) durante una prueba desde el punto de salida hasta llegar a la fuente correcta.




Figura A.4: Detalle en $t = 92600$ de las gráficas de la figura A.1.

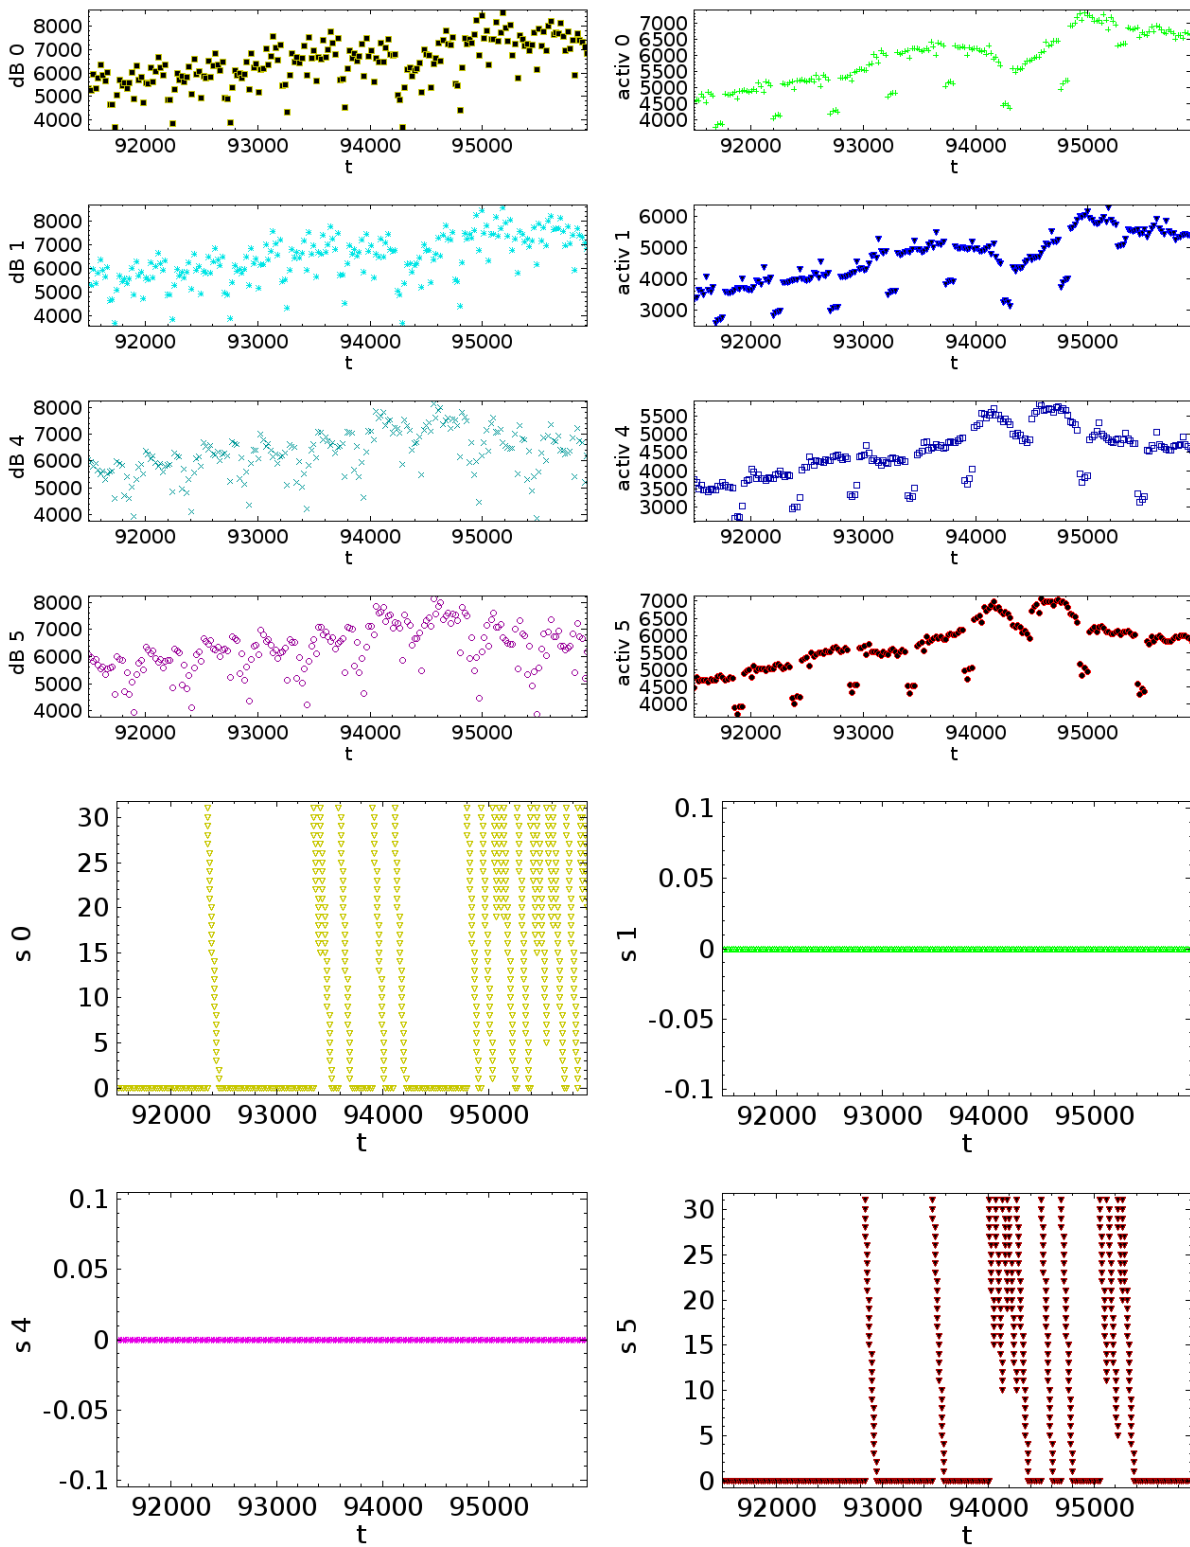


Figura A.5: Detalle en $t = 92600$ de las gráficas de la figura A.2.

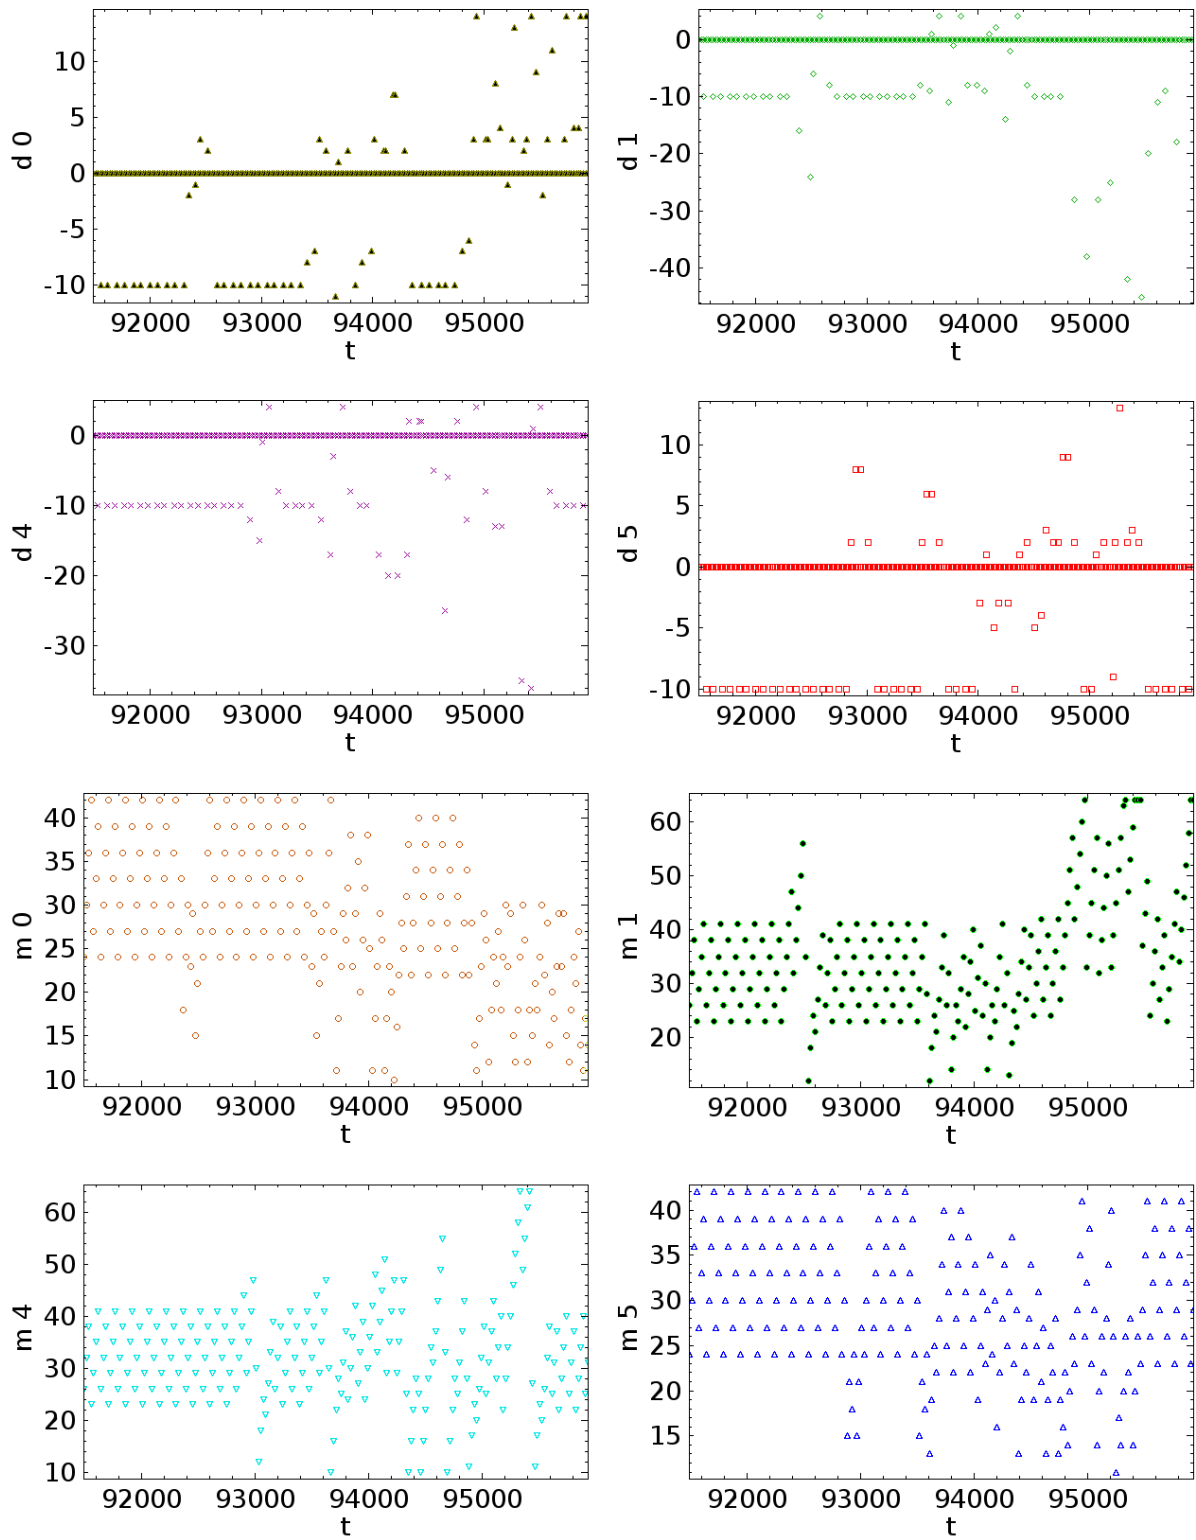


Figura A.6: Detalle en $t = 92600$ de las gráficas de la figura A.3.

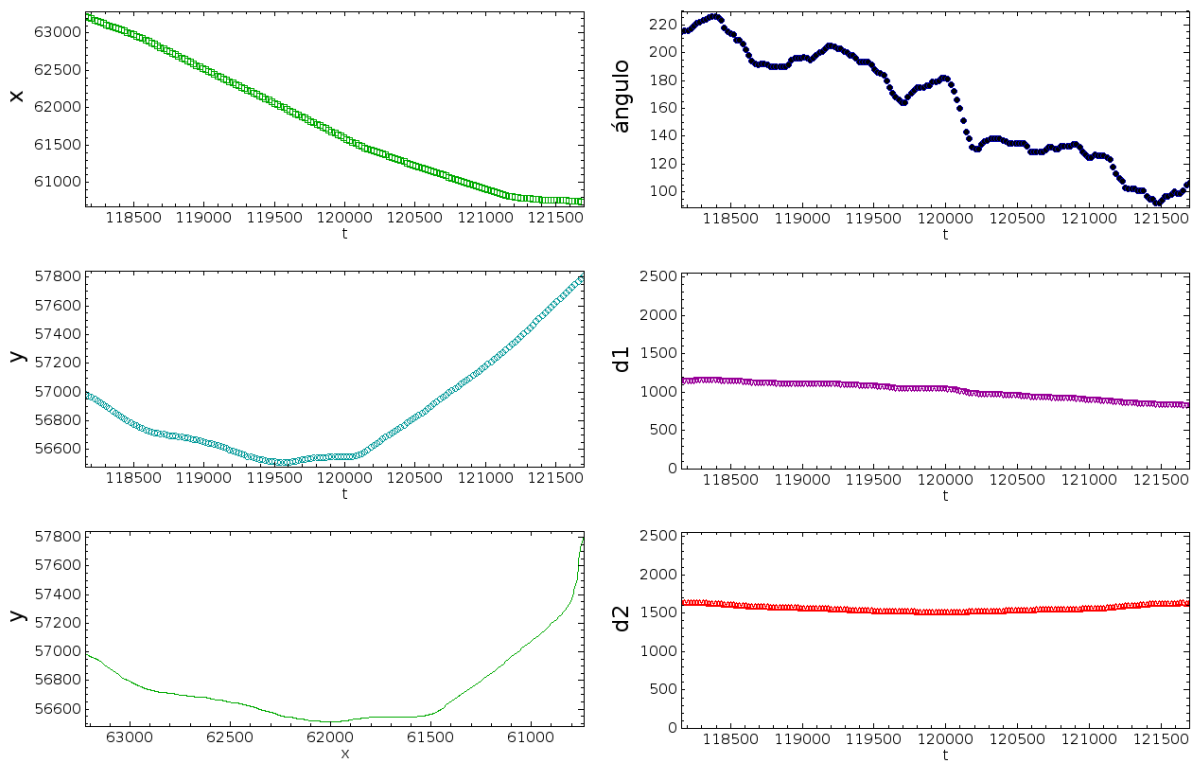


Figura A.7: Detalle en $t = 120000$ de las gráficas de la figura A.1.

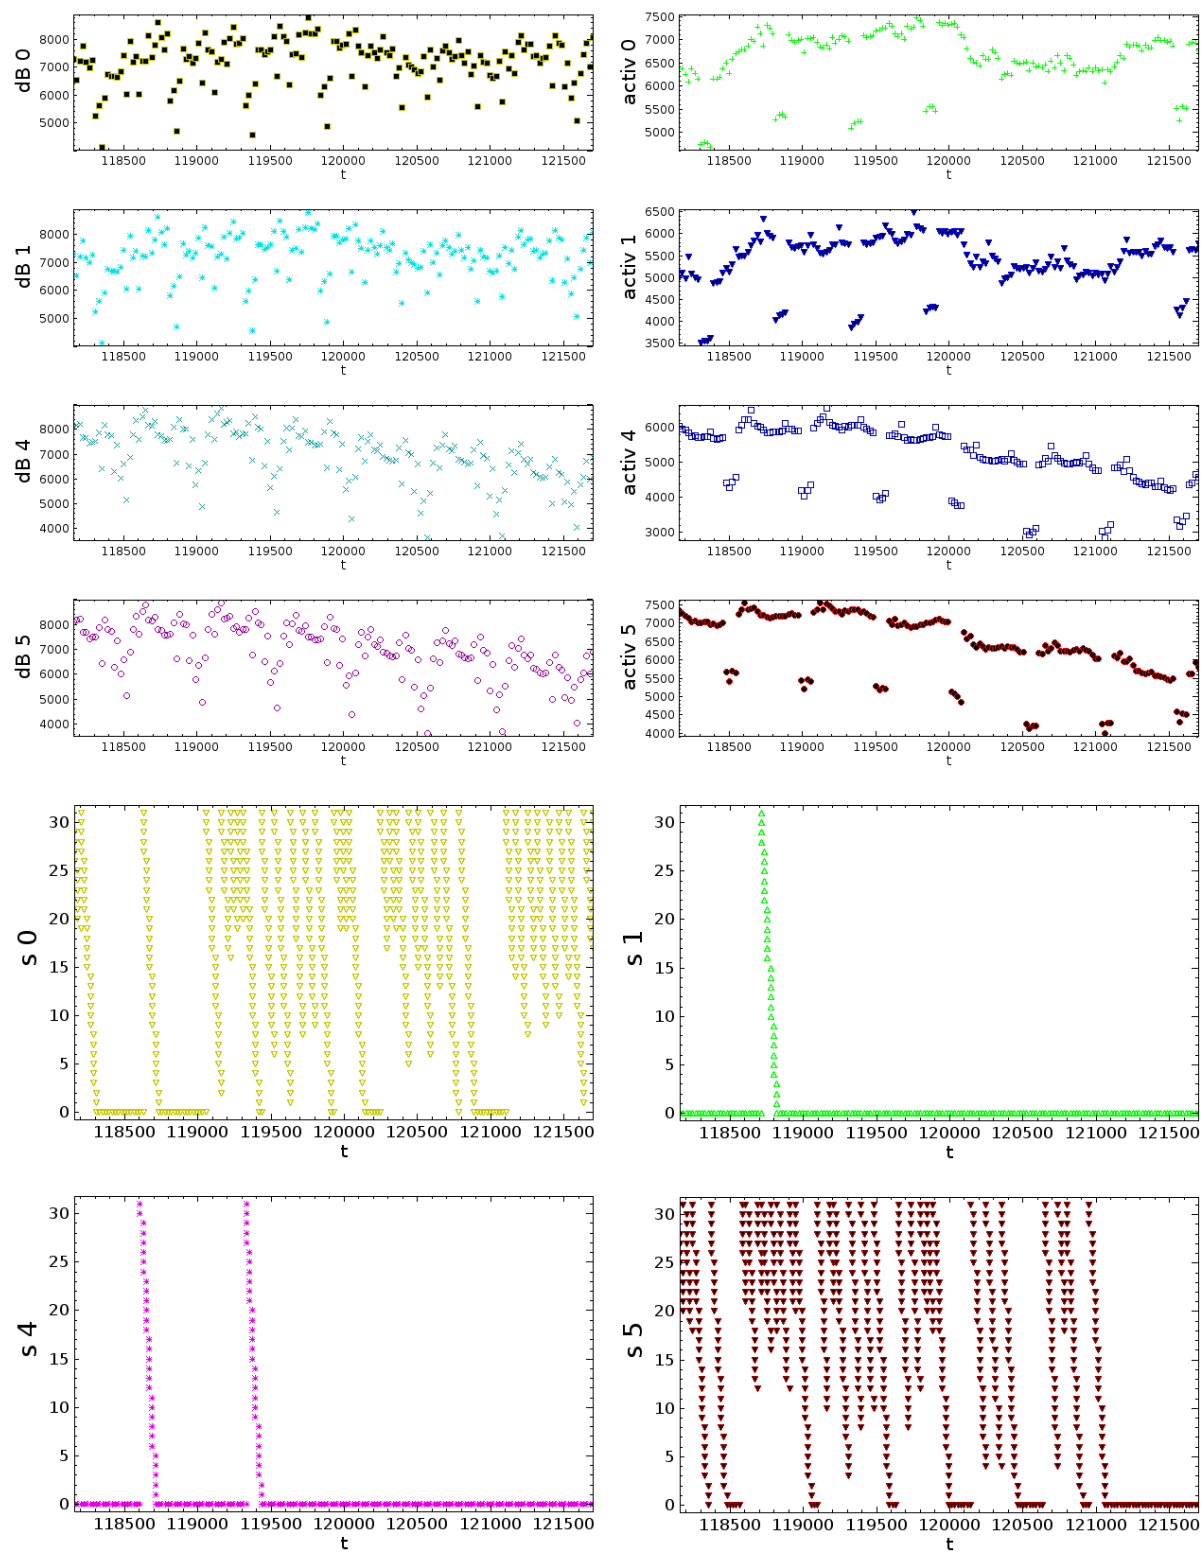


Figura A.8: Detalle en $t = 120000$ de las gráficas de la figura A.2.

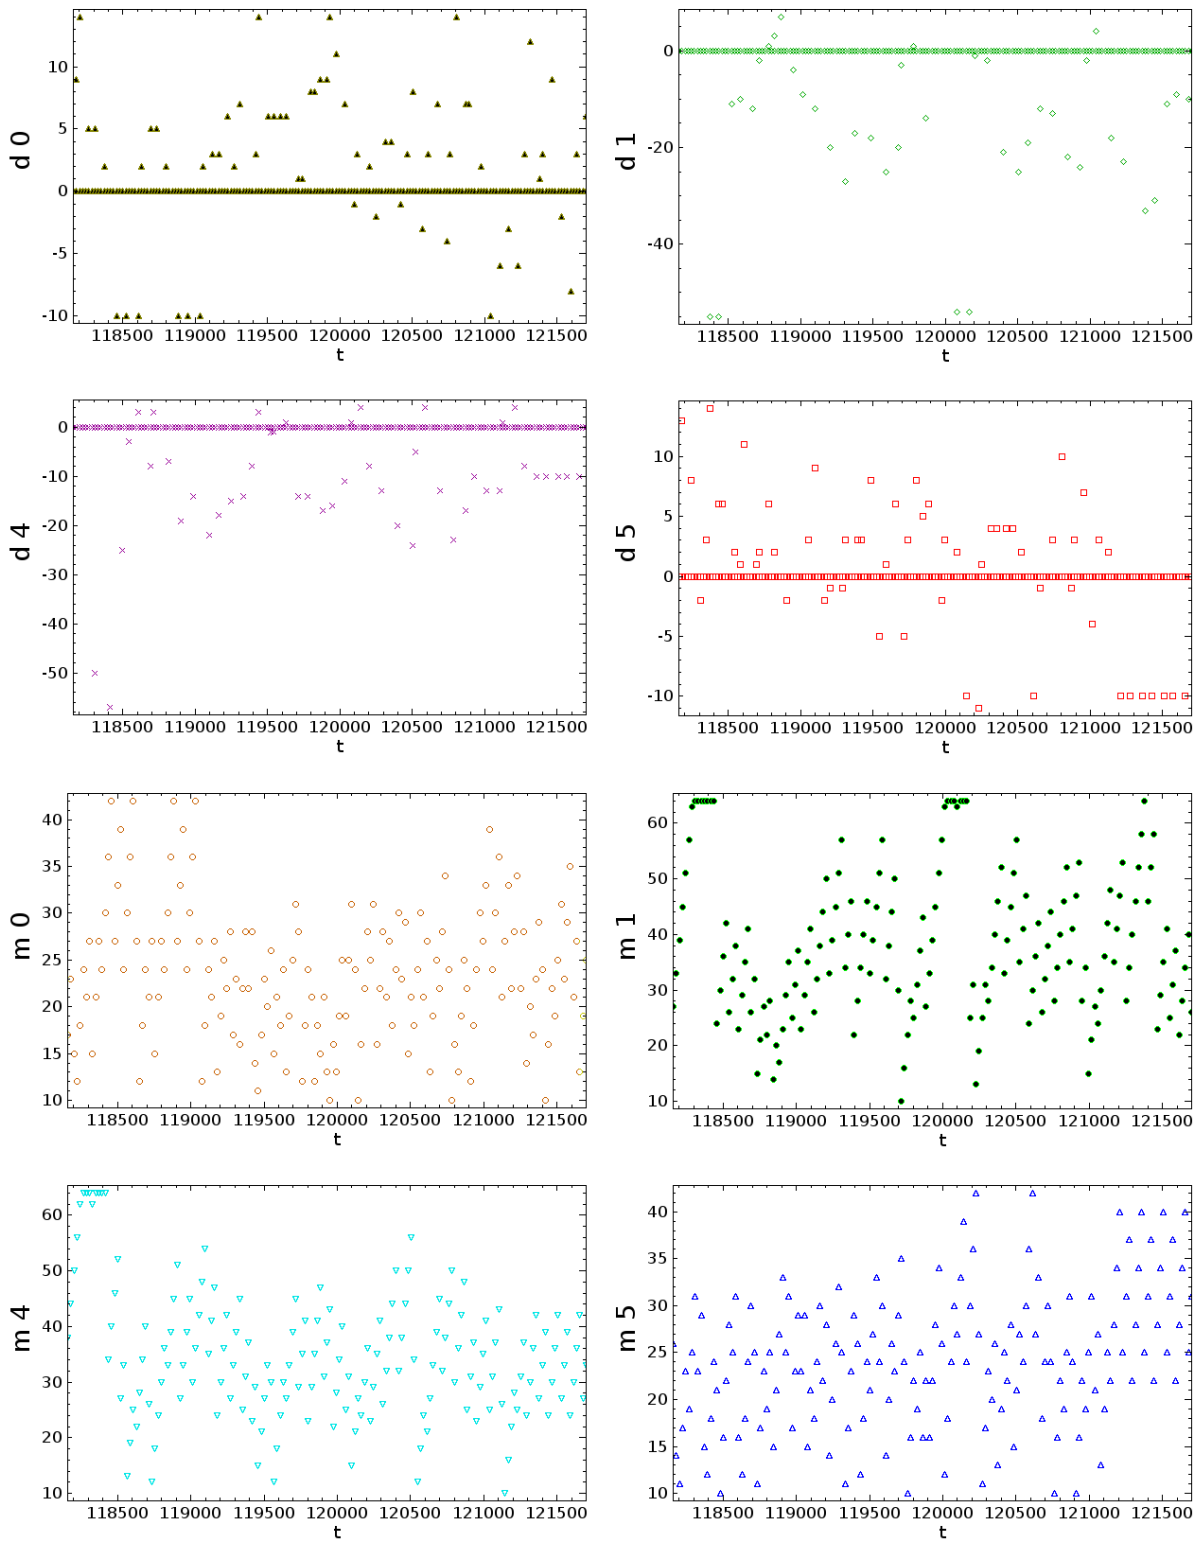


Figura A.9: Detalle en $t = 120000$ de las gráficas de la figura A.3.

El sonido y el oído. Psicoacústica

Al plantear una simulación simplificada pero fiel a cómo se *sienten* los sonidos por parte de la mayor parte de los mamíferos y muchos otros animales, es interesante describir de forma sencilla las principales ideas sobre la física del sonido, las matemáticas que lo describen y representan el proceso que se lleva a cabo en las diferentes partes del oído, y en general la percepción del sonido. Estos conceptos serán referidos al describir el sistema construido.

B.1. Naturaleza del sonido

El sonido se puede definir como los cambios de presión de un fluido (aire u otros gases o líquidos), originados por el movimiento o vibración de un objeto. Cuando la presión en un punto es mayor que la media, se dice que está en estado de *condensación*, y en caso contrario *rarefacción*. El aire no se desplace al transmitir un sonido, aunque sí se desplace la perturbación. La intensidad de la onda disminuye con la distancia. Concretamente, y al ser en un espacio tridimensional, la intensidad es inversamente proporcional al cubo de la distancia. Además, como toda onda sufre los fenómenos de reflexión, refracción y difracción.

Un sonido simple es una senoide que representa la variación de la presión respecto al tiempo. Se describe con tres parámetros: frecuencia ν en Herzios (Hz), amplitud A en decibelios (dB), y fase ϕ (o desfase) en radianes (rad). Su fórmula matemática es $y = A \cdot \text{sen}(\omega t + \phi)$, siendo $\omega = 2\pi\nu$.

Un sonido complejo también puede ser periódico. Por ello se percibe una característica subjetiva que se denomina *tono* (*pitch*), que se define como aquel atributo de la sensación perceptiva por el que los sonidos pueden ser ordenados en una escala musical. Variaciones en el tono crean una melodía, como por ejemplo una voz al cantar. El tono no es directamente cuantificable: su medida debe realizarse pidiendo a un sujeto que ajuste una senoide para que suene con el mismo tono que el sonido complejo. La frecuencia de la senoide se toma como medida del

tono del sonido.

B.2. Análisis de Fourier y espectro

Normalmente, los sonidos son complejos en cuanto a su composición en frecuencias y a cómo varían en el tiempo. Fourier demostró que toda función del tiempo periódica $x(t)$ puede ser descompuesta en un conjunto infinito de sinusoides con ciertas frecuencias, amplitudes y fases. En concreto (fórmula B.1):

$$x(t) = a_0 + \sum_{k=1}^{\infty} (a_k \cos(2\pi k f_0 t) + a_k \text{sen}(2\pi k f_0 t)) \quad \text{Transformada de Fourier Discreta} \quad (\text{B.1})$$

De esta forma, un sonido complejo se puede definir como la composición de unas determinadas sinusoides, con frecuencia múltipla de una frecuencia base f_0 , que corresponde al periodo de la función $x(t)$.

Las amplitudes (m), fases (ω) y frecuencias (ν) se obtienen a partir del número complejo $a_k + b_k i$, mediante las fórmulas

$$m = \sqrt{a_k^2 + b_k^2} \quad (\text{B.2})$$

$$\omega = td = \text{gcd}^{-1} \left(\frac{b_k}{a_k} \right) \quad (\text{B.3})$$

$$\nu = 2\pi f_0 k \quad (\text{B.4})$$

Para poder realizar análisis de Fourier sobre una señal de sonido es necesario tomar el sonido de un intervalo de tiempo, e interpretarlo como un periodo de una ficticia señal infinita periódica. De esta forma, se puede realizar sobre él (en realidad, sobre la señal ficticia) la Transformada de Fourier Discreta, en la que (mediante la fórmula anterior) se transforma la señal del dominio del tiempo al dominio de frecuencias.

Es un inconveniente que el tiempo necesario para realizar la transformada según la fórmula citada, sea proporcional al cuadrado de la longitud del trozo sobre el que se aplica (es pues, de orden $O(n^2)$), pues rápidamente se vuelve demasiado costosa computacionalmente. Por ello se han buscado métodos matemáticos para optimizar el algoritmo, y el que más se usa es el denominado Transformada Rápida de Fourier (*FFT*, en inglés) en base 2. Dicho algoritmo se aplica sobre trozos de datos de longitud 2^n , y es de orden $O(n \log_2 n)$. Como entrada tiene un vector de 2^n complejos (aunque el sonido tiene su parte imaginaria nula), y su resultado es también un vector de complejos $a_k + b_k i$. Si se le suministra a la FFT datos reales, su salida se compone de $n/2$ pares de complejos conjugados, es decir, con la parte imaginaria de signo contrario en cada elemento del par. Por ello, la información necesaria reside en los primeros $n/2$ complejos del vector. Cada complejo representa la amplitud y la fase para cada intervalo de frecuencia. Este vector es denominado *espectro de frecuencias* de la señal, compuesto por el espectro de amplitudes, y el espectro de fases.

La frecuencia máxima que puede digitalizar un sonido muestreado a f Hz es de $f/2$ Hz, según afirma el teorema de Nyquist. Por ejemplo, la música almacenada en un CD de música está descrita con las mediciones realizadas 44100 veces por segundo en cada canal del estéreo, es decir, muestreada a 44.100 Hz (con 16 bits por canal, que permiten valores entre -32768 y 32767 a las mediciones), y por tanto, como máximo, puede almacenar sonidos de hasta 22'1 kHz. Hay que señalar que, de media, el oído humano puede sentir sonidos entre 20 Hz y 20000 Hz (20 kHz).




Figura B.1: Representación de partes del canto de un canario en espectro de frecuencias (tiempo en horizontal y frecuencia en vertical, intensidad del sonido más alta en amarillo). Un sensor obtendría su activación con una franja horizontal de este gráfico, con una máxima amplitud igual a la zona superior de la V .

Por tanto, si la longitud de la muestra es de 2^n muestreos, la frecuencia mínima será de $f/2$ dividido entre $n/2$, es decir, f/n , y las demás serán proporcionales a ésta, o sea kf/n . De estas características se puede deducir que:

- cuanto más largo sea el trozo analizado, más precisión tendremos en los intervalos de frecuencias, más finos serán.
- cuanto más largo es el trozo analizado, peor definición temporal tendremos (si analizamos una centésima de segundo, obtendremos más datos de cómo varía el sonido que analizando cada medio segundo).
- cuanto mayor es la frecuencia de muestreo del sonido, más amplio es el rango de frecuencias que contiene, pero más coste computacional implica su FFT, y menor es su resolución en frecuencias con una misma longitud de análisis n .

B.3. Medida del nivel de sonido: dB

El sonido, al estar generado por un movimiento, acarrea una energía que le suministra dicho movimiento, y que irradia. La intensidad del sonido es, por tanto, la energía que pasa a través de una unidad de superficie en una unidad de tiempo (se mide en W/m^2). Se define un *Belio* (Bel) como $\log_{10}(I/I_0)$, siendo I la intensidad del sonido, e I_0 una intensidad de referencia.

Debido a que un belio es una unidad grande, normalmente se usan los *decibelios* (dB), que responden a la fórmula $10\log_{10}(I/I_0)$.

Como I_0 de referencia, se suele usar el valor $10^{-12}W/m^2$, y los dB que se toman sobre esta intensidad se denominan dB SPL (Nivel de Presión del Sonido). Esta intensidad base se eligió por ser el mínimo nivel de sonido detectable por el ser humano. El umbral absoluto medio para el ser humano es una senoide de 6'5 dB SPL a 1000 Hz. Si duplicamos la intensidad de un sonido, incrementamos su volumen en 3 dB, porque $10\log_{10}2 = 3'0103$ (el 2 significa duplicar de I_0 a $2I_0$). Si la dividimos por la mitad, $10\log_{10}0'5 = -3'0103$. Por ello, aunque parezca un pequeño cambio, subir en 6 dB el volumen de los graves en nuestro equipo de música es cuadruplicar la intensidad y por tanto la energía de la onda. Si acudimos a la Física, la energía de una onda crece con su longitud de onda (es decir, inversamente a su frecuencia): cuanto más grave es un sonido, más energía posee y por tanto, se escucha más lejos y puede traspasar paredes y otros obstáculos (pensemos en el *home theater* del vecino, sólo oímos los graves). Esto es también equivalente a la capacidad de penetración de las ondas electromagnéticas (rayos X, radiación nuclear...)

B.4. Linealidad

En el estudio de los Sistemas Dinámicos aparece el concepto de linealidad, aplicable a los sistemas que pueden ser descritos por ecuaciones lineales. Si el sistema produce una transformación f , ocurre que $f(x) + f(y) = f(x + y)$ y $2f(x) = f(2x)$ (*superposición y homogeneidad*, respectivamente).

Un sistema lineal es fácilmente modelable, ya que los errores que se introducen al realizar dicho modelo no afectan en exceso al resultado, por mantenerse en unos ciertos rangos. En cambio, un sistema no lineal puede amplificar los errores introducidos en el modelo, ya sean de concepto o en la estimación de parámetros, e incluso los estados posteriores del modelo pueden llegar a ser completamente falsos al ser decisivos los errores en la cuenca de un atractor extraño.

B.5. Filtros

Un filtro se puede definir como una transformación en el espectro independiente para cada rango de frecuencia. Los filtros más habituales son los que dejan pasar las frecuencias más altas que un determinado valor (*filtros pasa-alta*), y sus contrarios *filtros pasa-baja*. Un filtro *pasabanda* sería una composición de un pasa-baja y un pasa-alta con intersección no nula.

Un ecualizador de un equipo de música podría entenderse como un conjunto de filtros pasabanda, que componen sus salidas atenuadas o amplificadas en un número determinado de dB (el rango habitual es de ± 10 dB). Esta idea es de mucha ayuda al analizar el comportamiento del oído.

En la práctica es imposible diseñar filtros con cortes exactos, por lo que se define un filtro pasabanda especificando las frecuencias de corte y las pendientes. Se definen frecuencias de corte como las frecuencias a las que la salida del filtro decae 3 dB respecto la salida dentro de la pasabanda. Esto es una caída en potencia o intensidad a la mitad, y en amplitud o voltaje (si son filtros electrónicos) en $\sqrt{2}$.

Normalmente las pendientes de los filtros son proporcionales al logaritmo de la frecuencia. Por ello, se ha buscado una unidad de frecuencia logarítmica, que es la *octava*. Un par de frecuencias están separadas por n octavas si $f_1/f_2 = 2^n$. Es decir, si se aumenta una octava, la frecuencia se duplica. Por ejemplo, un sonido blanco (senoide puro) en la nota Do (C en terminología anglosajona) en octava 4 es 262 Hz, y un Do en octava 5 es 524

Hz. La anchura de un filtro puede ser determinada en octavas, y la pendiente en dB/octava.

B.6. Estructura y función básicas en el sistema auditivo

Vamos a realizar una descripción de la estructura y funciones de las partes del sistema auditivo humano, que aproximadamente es igual al de cualquier otro mamífero. Es claramente distinguible el oído externo, el medio y el interno, ya que estructuralmente componen subsistemas bien diferenciados.

B.6.1. Oído externo y medio

El oído externo está compuesto por la pinna (la parte externa, la oreja) y el canal auditivo o meato. La pinna ha sido considerada habitualmente como una parte poco importante en del sistema auditivo, pero es fácilmente comprobable que modifica el sonido, particularmente a altas frecuencias, y por ello resulta importante en la habilidad de localizar sonidos (*percepción espacial*). El sonido es reflejado por la pinna y canalizado por el meato, llega al tímpano y le provoca una vibración. Esa vibración se transmite a través del oído medio por cuatro huesecillos, los osículos, hasta una apertura en la pared ósea que recubre la cóclea u oído interno. Esta ventana recubierta de una membrana se llama ventana oval. Estos huesecillos se llaman lenticular, yunque, martillo y estribo, y son los más pequeños de todo el cuerpo. La transmisión es inversamente equivalente a la de la débil presión del pie sobre el pedal de freno de un coche, que es convertida por el servomecanismo en una gran presión que actúa sobre los émbolos de las pastillas de freno.

La función principal del oído medio es asegurar la transmisión del sonido del aire a la cóclea de una forma eficiente. Si el sonido llegase directamente a la ventana oval, se reflejaría casi totalmente en vez de entrar en la cóclea. Esto sería así porque la resistencia de la ventana oval al movimiento es muy diferente a la del aire. Técnicamente se denomina *diferencia de impedancias acústicas*. Se basa principalmente en las diferentes superficies del tímpano y de la ventana oval. La transmisión del sonido a través del oído medio es más eficiente a frecuencias medias (de 500 a 4000 Hz).

Los huesecillos están controlados por ciertos músculos (acordes con su tamaño), que se contraen cuando el oído se expone a sonidos intensos. Esta contracción, conocida como el reflejo del oído medio, no se conoce completamente, especialmente su control. El reflejo reduce la transmisión de sonido a través del oído medio, pero sólo a bajas frecuencias, y puede ayudar a prevenir daños en las delicadas estructuras de la cóclea. Sin embargo, este reflejo es demasiado lento para proteger de sonidos como disparos o golpes de martillo, aunque este tipo de sonidos no son habituales en la Naturaleza, por lo que no han influido en la evolución de este sistema. Otras posibles funciones pueden ser reducir la intensidad del sonido generado por el propio individuo, principalmente el habla.

B.6.2. Oído interno y membrana basilar

La cóclea es la parte más importante del oído, ya que en ella se produce la transducción de energía mecánica a electromagnética en las neuronas, clave para el funcionamiento del sentido. La cóclea está llena de líquidos prácticamente incompresibles (podemos de nuevo pensar en sistemas hidráulicos como el circuito de frenos de un coche, con un líquido equivalente), y sus paredes son óseas. Está dividida a lo largo por dos membranas, la *membrana de Reissner* y la *membrana basilar*. La ventana oval está situada al principio de la cóclea, la *base*. El otro extremo, el interno, es el *ápice*. Un movimiento de la ventana oval produce otro movimiento en la membrana que cubre la otra apertura en la cóclea, la *ventana redonda*, y de esta forma se mantiene la presión constante.

Cuando la ventana oval se mueve debido a un sonido, se produce una diferencia de presión en la membrana basilar. La onda de presión viaja casi de forma instantánea a través de los líquidos de la cóclea, y la diferencia de presión es ejercida simultáneamente en toda la longitud de la membrana basilar. La respuesta de la membrana basilar es diferente en cada punto, debido a su anchura. En la base es estrecha y rígida, y en el ápice es ancha y poco rígida. Por ello, los sonidos de alta frecuencia producen un desplazamiento máximo de la membrana basilar cerca de la ventana oval (la base), y queda poco movimiento en el resto de la membrana. Los sonidos de baja frecuencia producen un patrón de vibración que se extiende a lo largo de toda la membrana, pero que alcanza un máximo antes del fin de la misma.

Es de destacar que, si exponemos la membrana basilar a un sonido continuo sinusoidal, todos los puntos de la membrana vibrarán de una forma aproximadamente sinusoidal con una frecuencia igual a la de la onda de entrada, aunque con diferentes amplitudes y fases.

Se puede considerar que cada punto de la membrana es un filtro pasabanda. De esta forma, puede definirse con un ancho de banda, una frecuencia central, y con una pendiente en dB/octava. Debido a que la medida de 3 dB es difícil, se suele medir una caída de 10 dB. Además, en muchos tipos de filtros, y también en la membrana basilar, el ancho de banda no es constante, sino que es aproximadamente proporcional a la frecuencia, y por ello se usa el ancho de banda relativo, que es el absoluto dividido entre la frecuencia central. El recíproco de este valor describe la resolución del sistema, y se denota por Q_{10dB} .

Ciertos trabajos recientes muestran que la vibración de la membrana basilar es no lineal, y que la no linealidad decrece según empeora el estado fisiológico de la cóclea, de tal forma que con la muerte su respuesta es lineal. De la misma forma decrece la agudeza, es decir, la alta sensibilidad a un rango limitado de frecuencias. Esto sugiere que existe un proceso biológico activo responsable de la agudeza y de la no linealidad, y la importancia del comportamiento no lineal en el proceso auditivo, provocado por mecanismos motores que son controlados por el sistema auditivo mediante un sistema de retroalimentación (*feedback*), además de por las características fisiológicas de la membrana basilar ante sonidos complejos en frecuencia, amplitud, fase y durante el tiempo.

B.6.3. El proceso de transducción y las células ciliares

Hasta ahora nos hemos centrado en la respuesta mecánica de la membrana basilar al sonido. Pasemos a describir la transformación de ese movimiento a señales neuronales en el sistema nervioso auditivo.

Entre la membrana basilar y la membrana tectorial están las células ciliares, que forman parte del *órgano de Corti*. Están separadas en dos grupos por el túnel de Corti. Las que pertenecen al grupo más exterior de la cóclea se llaman células ciliares externas, y están organizadas en tres líneas en los gatos y hasta en cinco en los humanos. Las del otro grupo forman una sola línea, y se denominan células ciliares internas. Hay unas 25000 células ciliares externas, cada una con 140 cilios, y 3500 internas, cada una con 40 cilios. La membrana tectorial está situada sobre los cilios, y parece que los de las externas la tocan. El funcionamiento básico es que el movimiento de la membrana basilar produce un movimiento relativo de la membrana tectorial, que a su vez mueve los cilios de las internas, con lo cual generan una diferencia de potencial en las neuronas conectadas a las células ciliares internas.

Se desconocen muchos detalles de este proceso, aunque parece claro que las células ciliares tienen funciones claramente diferenciadas. La mayoría de las neuronas aferentes, que llevan información desde la cóclea hacia el sistema nervioso auditivo, conectan a las células ciliares internas. Cada una de éstas se conecta con unas veinte neuronas. Hay unos 1800 nervios eferentes desde el sistema nervioso auditivo hacia la cóclea, y muchos conectan con las células ciliares externas, modificando así su función motora. Por tanto, se puede decir que su papel consiste en influir en la mecánica de la cóclea, y modificar su respuesta ante el sonido.

B.6.4. Respuesta del nervio auditivo

En muchos estudios recientes se ha medido el comportamiento de fibras nerviosas auditivas individuales a través de microelectrodos que recogen los impulsos nerviosos o disparos (*spikes*). Hay tres resultados generales, que parecen ser válidos para todos los mamíferos:

- Las fibras nerviosas muestran un comportamiento de disparos espontáneo en ausencia de estimulación sonora. Las tasas de disparo espontáneo van de cerca de 0 a 150 por segundo.
- Las fibras responden a ciertas frecuencias mejor que a otras.
- Las fibras tienen un comportamiento de sincronización de fase: los disparos suelen ocurrir en un momento determinado (una fase) de la onda sonora. Por ello hay un comportamiento periódico (regularidad temporal) en los disparos de una neurona en respuesta a un estímulo periódico.

B.6.5. Umbrales y tasa de disparos espontáneos

Un 61 % de las fibras nerviosas se disparan entre 18 y 250 veces por segundo. Las tasas espontáneas están en correlación con el tamaño y la posición de las sinapsis de las células ciliares internas. Las tasas más bajas están asociadas con las sinapsis más pequeñas del lado opuesto de las células ciliares.

Los umbrales de las neuronas están también en correlación con las tasas. El umbral es el nivel mínimo de sonido en el que se puede medir un cambio en la respuesta de una neurona. Las neuronas más sensibles tienen umbrales cercanos a 0 dB SPL, y habitualmente tienen tasas espontáneas altas. El caso contrario son las neuronas con umbrales de 80 dB SPL o más.

La selección de frecuencia de una fibra nerviosa se suele mostrar como una curva que relaciona el umbral con la frecuencia, y se denomina Curva Frecuencia-Umbral. La frecuencia a la que el umbral de la fibra es el menor es la **Frecuencia Característica (FC)**.

Las FC están relacionadas tanto en la posición de la conexión de la fibra con la cóclea, como en la posición de la fibra en el nervio auditivo. Esta estructuración es conocida como tonotópica.

La distancia entre el umbral y la saturación de la neurona es el *rango dinámico*, y suele ser unos 30 a 40 dB. Si observamos la respuesta de una neurona (en disparos por segundo) ante un sonido (en dB relativos a su umbral), se puede observar una función del tipo sigmoideo (del aspecto de la arcotangente).

Se puede destacar que, dentro de su rango dinámico, el comportamiento es fiable, y se vuelve irregular con frecuencias de disparo muy bajas o muy altas, cuando la excitación es baja o la neurona se satura.

El rango dinámico está correlado de tal forma que las tasas espontáneas altas y umbrales bajos corresponden con rangos dinámicos pequeños (neuronas muy sensibles). Casi todas las neuronas están dentro del rango de 20 a 50 dB, excepto unas que muestran un comportamiento llamado “saturación en pendiente”, en el que la tasa de disparo aumenta proporcionalmente con el volumen de sonido, aun en niveles altos de sonido. Este comportamiento se produce principalmente en neuronas con tasas espontáneas bajas.

B.6.6. Sincronización de fase (*Phase locking*)

El sonido se caracteriza también por la fase de las ondas que lo componen, y este parámetro de la fase parece ser importante en la percepción espacial. Fijémonos en cómo transmite esta característica a través de las células

ciliares internas al nervio auditivo. Hemos visto en el punto anterior que las neuronas se disparan en función de la intensidad del sonido que las estimula, y esto modifica su tasa de disparo, que medimos en disparos por segundo. Cuando una neurona se dispara, tiende a hacerlo en la misma fase de la onda. Si tenemos en cuenta un grupo de neuronas que responden al mismo estímulo, siempre habrá un disparo que indicará la fase del sonido, y de la frecuencia de disparo se podrá extrapolar la intensidad. De qué neuronas se disparan se obtiene la frecuencia de la onda, ya que no sólo se disparan la de frecuencia característica igual a la frecuencia de la onda.

Pero no debería sorprendernos este hecho si tenemos en cuenta el proceso de transducción. En éste, el movimiento de las células ciliares se produce por el movimiento de la membrana basilar, y la excitación neuronal se produce únicamente cuando el movimiento es en un determinado sentido.

Parece ser que, debido al tiempo refractario de las neuronas, los disparos no se producen en todos los ciclos de la onda. Aun así, existe una proporción entre la frecuencia de la onda y cada cuántos ciclos se dispara la neurona.

La sincronización de fase no se produce para todas las frecuencias audibles. Esta capacidad se pierde a los 4 a 5 kHz, debido a que la precisión que resulta suficiente para frecuencias bajas, no lo resulta a partir de estos valores.

B.6.7. Percepción del volumen

De la misma forma en que la vista se acomoda a la intensidad de luz y nos permite ver tanto en un día soleado sobre la nieve como en una habitación a oscuras con la débil luz de un LED, el sentido del oído ajusta su sensibilidad. En el silencio de la noche podemos oír pequeños ruidos, y en una discoteca a duras penas conseguimos entender a quien está al lado. Para ello el oído dispone de sistemas de protección ya descritos, aparte de usar distintos grupos de neuronas cuyo rango dinámico se encuentra en unas ciertas intensidades del sonido.

B.6.8. Percepción espacial: Cono de confusión y papel de los movimientos de la cabeza

La localización de la fuente del sonido se basa en un cálculo basado en la amplitud de las señales que llegan a ambos oídos, ligeramente menor en el más lejano y más aún si en el camino está la propia cabeza, y la fase, distinta para las diferentes frecuencias por la misma razón. Por ello nos resulta más difícil localizar un sonido puro que uno compuesto. Hay que subrayar el papel de la cabeza como obstáculo, ya que las ondas más graves la rodean atenuándose y cubriendo más distancia, y las agudas no son capaces de evitar, con lo que dan una clara diferencia.

Sin embargo, podemos deducir más de un posible punto fuente del sonido, y por ello los descartamos moviendo la cabeza para obtener más información.

Todavía está en estudio las estructuras simétricas del cerebro humano que estiman el *azimut* o ángulo de incidencia del sonido percibido, teniendo en cuenta que parece más importante la componente horizontal de este ángulo. Sí que se sabe que el núcleo olivar superior hace esta tarea. La oliva medial superior mide las diferencias temporales (o de fase, importantes en bajas frecuencias) y la oliva lateral superior mide las diferencias en intensidad para los sonidos de alta frecuencia (Kandel et al., 2000; Gray, 1918).

B.6.9. Percepción espacial: Localización monoaural y la importancia del oído externo

Aun sin mover la cabeza sabemos si el sonido proviene de delante o de detrás, incluso con un solo oído. Esto es debido al oído externo, que filtra las frecuencias con un patrón que aprendemos, y nos permite detectar minúsculos

cambios de volumen que nos informan del ángulo de incidencia del sonido en un solo oído.

B.7. Ejemplo de activación neuronal

En trabajos como el de Nieder y Klump (1999) se obtienen gráficos como éste de la figura B.2, en el que se representa la activación de una neurona sensora de estornino. Se mide con electrodos la respuesta para cada frecuencia y volumen (intensidad) del sonido. La neurona se activa de forma proporcional a la longitud de la línea vertical que se encuentra en el punto determinado por una cierta frecuencia e intensidad.




Figura B.2: Activación de una neurona sensora de estornino para cada frecuencia y volumen del sonido. Figura de Nieder y Klump (1999)

Como se puede observar, la activación es muy alta en una zona con forma de *V* cuyo vértice está en la frecuencia característica. El área está flanqueada por dos zonas en las que hay una inhibición de la activación, que recuerda a las teorías que tratan sobre las diferencias entre la forma y el fondo.



Bibliografía

- ALONSO, E., 2006. Aspectos Filosóficos de la Inteligencia y la Computación. En S. Fernández-Caballero, Miguel Tomé, ed., *50 años de la Inteligencia Artificial*, 25–41. Universidad de Castilla-La Mancha. 21
- ARKIN, R., 1998. *Behavior-Based Robotics*. MIT Press, Cambridge, MA. 3, 4, 11, 44
- BARANDIARAN, X. Y MORENO, A., 2006. ALife Models as Epistemic Artefacts. En L. Rocha, L. Yaeger, M. Bedau, D. Floreano, R. Goldstone y A. Vespignani, eds., *Alife X: 10th International Conference on the Simulation and Synthesis of Living Systems*, 513–519. Cambridge, MIT Press. 44
- BARR, A., FEIGENBAUM, E. A. Y COHEN, P. R., 1986. *Handbook of AI*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA. ISBN 0201118106. 15
- BECERRA, J. A., BELLAS, F., REYES, J. S. Y DURO, R. J., 2005. Complex Behaviours Through Modulation in Autonomous Robot Control. En J. Cabestany, A. Prieto y F. S. Hernández, eds., *IWANN*, Volumen 3512 de *Lecture Notes in Computer Science*, 717–724. Springer. ISBN 3-540-26208-3. 37
- BECHTEL, W., 2007. *Mental Mechanisms. Philosophical Perspectives on Cognitive Neuroscience*. Lawrence Erlbaum, Hillsdale. ISBN 0805863346. 6
- BEER, R., 1994. A Dynamical Systems Perspective on Agent-Environment Interaction. En T. Smithers y A. Moreno, eds., *On the role of Dynamics and Representation in Adaptive Behaviour and Cognition III International Workshop on Artificial Life (DRABC94)*. Euskal Herriko Unibertsitatea, Universidad del País Vasco. 35
- BEER, R., 1995. On the dynamics of small continuous-time recurrent neural networks. *Adaptive Behavior*, **3(4)**, 469–509. 37, 39, 40
- BEER, R. Y GALLAGHER, J., 1992. Evolving Dynamical Neural Networks for Adaptive Behavior. *Adaptive Behavior*, **1(1)**, 91–122. 35

- BOOLE, G., 1854. *An Investigation of the Laws of Thought on Which are Founded the Mathematical Theories of Logic and Probabilities*. Macmillan. 16
- BOURGINE, P. Y VARELA, F., 1992. Toward a practice of autonomous systems. En F. J. Varela y e. Paul Bourguine, eds., *Toward a practice of autonomous systems: Proceedings of the first European Conference on Artificial Life*, ix–xvii. Cambridge, MA, MIT Press. 47
- BRAITENBERG, V., 1984. *Vehicles. Experiments in Synthetic Psychology*. MIT Press, MA. 24
- BROOKS, D., 1995. The Unified Theory: And Selection Processes. En *International Symposium on Evolutionary ISES'95*. 48
- BROOKS, D. Y WILEY, E., 1986. *Evolution as Entropy: Toward a unified Theory of Biology*. Chicago: Chicago University Press. 48
- BROOKS, R., 1990. Elephants don't play chess. *Robotics and Autonomous Systems*, **6**, 3–15. 6, 21, 22, 23, 27
- BROOKS, R., 1991a. Intelligence without reason. En J. Myopoulos y R. Reiter, eds., *Proc. 12th IJCAI*, 569–595. Morgan Kaufmann publishers Inc.: San Mateo, CA. 6, 22, 23, 28, 47
- BROOKS, R., 1991b. Intelligence without representation. *Artificial Intelligence*, **47**, 139–159. 22, 23, 27, 28
- BURNS, E. Y WARD, W., 1978. Categorical perception–phenomenon or epiphenomenon: evidence from experiments in the perception of melodic musical intervals. *J Acoust Soc Am*, **63**, 456–468. 38
- CARIANI, P., 1989. *On the design of devices with emergent semantic functions*. Tesis Doctoral, State University of New York, Binghamton. 47
- CARIANI, P., 1992. Emergence and Artificial Life. En C. G. Langton, C. Taylor, J. D. Farmer y S. Rasmussen, eds., *Artificial Life II*, 775–797. Addison-Wesley, Redwood City, CA. 47
- CARIANI, P., 1998. Towards an evolutionary semiotics: The emergence of new sign-functions in organisms and devices. En G. Van de Vijver, S. Salthe y M. e. Delplos, eds., *Evolutionary Systems. Biological and Epistemological Perspectives on Selection and Self-Organization*, 359–376. Dordrecht: Kluwer. 47
- CLIFF, D., HARVEY, I. Y HUSBANDS, P., 1993. Explorations in Evolutionary Robotics. *Adaptive Behavior*, **2(1)**, 71–108. 29, 45
- COHEN, I. B., 1998. Howard Aiken on the number of computers needed for the nation. *Annals of the history of computing*, **20**, 27–32. 16
- COLLIER, J., 1986. Entropy in Evolution. *Biology and Philosophy*, **1**, 5–24. 48
- CRAIG, J. J., 1989. *Introduction to Robotics: Mechanics and Control*. Addison-Wesley Longman Publishing Co., Inc., Boston, MA, USA. ISBN 0201095289. 4
- DARWIN, C., 1859. *The Origin of species by means of natural selection*. Modern Library, New York. 27
- DELLAERT, F. Y BEER, R., 1995. Toward an evolvable model of development for autonomous agent synthesis. 35
- DI PAOLO, E. A., 2002. *Evolutionary robotics (S. Nolfi and, D. Floreano)*, Volumen 14 de *Connection Science*, cap. Review. MIT Press. 29, 58, 79

- DI PAOLO, E. A., 2003a. Evolving spike-timing dependent plasticity for single-trial learning in robots. *Philosophical Transactions of the Royal Society A.*, **361**, 2299–2319. [29](#), [40](#), [41](#)
- DI PAOLO, E. A., 2003b. *Organismically-inspired robotics: Homeostatic adaptation and natural teleology beyond the closed sensorimotor loop*, Volumen Dynamical Systems Approach to Embodiment and Sociality, 19–42. Advanced Knowledge International, Adelaide, Australia. [24](#), [29](#)
- ETXEBERRIA, A., 1995. *Vida Artificial. Bases teóricas y metodología*, Volumen Vida Artificial, 15–35. Albacete: Ed. Universidad de Albacete, Colección Estudios. [23](#)
- FERNÁNDEZ-CABALLERO, MIGUEL TOMÉ, S., ed., 2006. *50 años de la Inteligencia Artificial*. Universidad de Castilla-La Mancha. [22](#)
- FERNÁNDEZ OSTOLAZA, J. Y MORENO, A., 1992. *Vida Artificial*, Volumen Vida Artificial. Eudema, Madrid. [23](#)
- FLOREANO, D., EPARS, Y., ZUFFEREY, J. Y MATTIUSSI, C., 2006. Evolution of Spiking Neural Circuits in Autonomous Mobile Robots. *International Journal of Intelligent Systems*, **21**. [40](#)
- FLOREANO, D. Y MATTIUSSI, C., 2001. Evolution of Spiking Neural Controllers for Autonomous Vision-based Robots. En T. Gomi, ed., *Evolutionary Robotics IV*, 3–10. Berlin, Springer-Verlag. [10](#), [11](#), [25](#), [40](#)
- FLOREANO, D. Y MONDADA, F., 1994a. Active Perception and Grasping: an Autonomous Perspective. En P. Gaussier y J.-D. Nicoud, eds., *Proceedings of the PerAc conference*. Lausanne, Switzerland, IEEE Computer Society Press. [31](#)
- FLOREANO, D. Y MONDADA, F., 1994b. Automatic Creation of an Autonomous Agent: Genetic Evolution of a Neural-Network Driven Robot. En D. Cliff, P. Husbands, J. Meyer y S. Wilson, eds., *From Animals to Animats III: SAB'94*. MIT Press-Bradford Books, Cambridge, MA. [27](#), [31](#)
- FLOREANO, D. Y MONDADA, F., 1996. Evolution of Homing Navigation in a Real Mobile Robot. *IEEE Transactions on Systems, Man and Cybernetics*, **26(3)**, 396–407. [31](#), [45](#)
- FRANZ, M. Y MALLOT, H., 2000. Biomimetic robot navigation. *Robotics and Autonomous Systems*, **30**, 133–153. [4](#)
- FUNAHASHI, K. Y NAKAMURA, Y., 1993. Approximation of dynamical systems by continuous time recurrent neural networks. *Neural Netw.*, **6(6)**, 801–806. ISSN 0893-6080. [39](#)
- GOLDBERG, D. E., 1989. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley, Reading, MA. [3](#), [41](#), [42](#)
- GOMI, T. Y GRIFFITH, A., 1996. Evolutionary Robotics- An overview. En *Proceedings de ICEC'96, IEEE96 International Conference on Evolutionary Computation*. [27](#), [36](#)
- GONZÁLEZ-NALDA, P. Y CASES, B., 2006a. Topos: generalized Braitenberg vehicles that recognize complex real sounds as landmarks. En L. Rocha, L. Yaeger, M. Bedau, D. Floreano, R. Goldstone y A. Vespignani, eds., *Alife X: 10th International Conference on the Simulation and Synthesis of Living Systems*, 213–219. Cambridge, MIT Press. [51](#), [89](#)

- GONZÁLEZ-NALDA, P. Y CASES, B., 2006b. TOPOS: reconocimiento de patrones temporales en sonidos reales con redes neuronales de pulsos. En A. Fernández-Caballero, M. Gracia Manzano, E. Alonso y S. Miguel Tomé, eds., *Una perspectiva de la Inteligencia Artificial en su 50 aniversario*, 243–248. Universidad de Castilla-La Mancha. 51, 89
- GONZÁLEZ-NALDA, P. Y CASES, B., 2008. Topos: Spiking neural networks for temporal pattern recognition in complex real sounds. *Neurocomputing*, **71**(4-6), 721–732. ISSN 0925-2312. URL <http://dx.doi.org/10.1016/j.neucom.2007.07.032>. 26, 51, 89
- GRAY, H., 1918. *Anatomy of the Human Body (Gray's Anatomy)*. Philadelphia: Lea & Febiger. 114
- GUBERN, R., 1987. *El simio informatizado*. Fundesco, Madrid. 20
- HANDEL, S., 1989. *Listening: An Introduction to the Perception of Auditory Events*. The MIT Press, Cambridge, MA. 53, 61
- HARVEY, I., 1995. *The artificial evolution of adaptive behaviour*. Tesis Doctoral, University of Sussex. 29, 34, 42
- HARVEY, I., DI PAOLO, E., WOOD, R., QUINN, M. Y TUCI, E. A., 2005. Evolutionary Robotics: A new scientific tool for studying cognition. *Artificial Life*, **11**(1-2), 79–98. 8, 27, 29
- HARVEY, I., HUSBANDS, P. Y CLIFF, D., 1992. Issues in Evolutionary Robotics. En J.-A. Meyer, H. Roitblat y S. Wilson, eds., *2nd Intl. Conf. on Simulation of Adaptive Behavior, SAB2*, 364–373. MIT Press//Bradford Book. 29
- HARVEY, I., HUSBANDS, P. Y CLIFF, D., 1994. Seeing the light: Artificial evolution, real vision. En D. Cliff, P. Husbands y J.-A. Meyer, eds., *From Animals to Animats 3. Proceedings of the Third International Conference on Simulation of Adaptive Behavior*, 392–402. MIT Press, Cambridge, MA. 27, 44, 47
- HARVEY, I., HUSBANDS, P., CLIFF, D., THOMPSON, A. Y JAKOBI, N., 1997. Evolutionary robotics: the Sussex approach. *Robotics and Autonomous Systems.*, v. **20**, 205–224. 45
- HAUGELAND, J., 1985. *Artificial Intelligence: The Very Idea*. Cambridge, Massachusetts: Bradford/MIT Press. 21
- HEBB, D. O., 1949. *The Organization of Behavior: A Neuropsychological Theory*. John Wiley and Sons, New York. 11, 16
- HOLLAND, J., 1975. *Adaptation in Natural and Artificial Systems*. U. Michigan Press. 41, 42
- HORCHLER, A., REEVE, R., WEBB, B. Y QUINN, R., 2003. Robot Phonotaxis in the Wild: a Biologically Inspired Approach to Outdoor Sound Localization. En *Proceedings of 11th International Conference on Advanced Robotics (ICAR'2003)*, 18(8):801–816. VSP. 25
- HUSBANDS, P., HARVEY, I., CLIFF, D. Y MILLER, G., 1994. The use of genetic algorithms for the development of sensorimotor control systems. En P. Gaussier y J.-D. Nicoud, eds., *Proceedings of the From Perception to Action Conference (PerAc'94)*, 110–121. IEEE Computer Society Press. 53
- HUSBANDS, P., HARVEY, I., CLIFF, D. Y MILLER, G. F., 1997. Artificial Evolution: A New Path for Artificial Intelligence? *Brain and Cognition*, **34**, 130–159. 45
- IZHIKEVICH, E. M., 1998. Phase models with explicit time delays. *Phys. Rev. E*, **58**(1), 905–908. 40

- IZHIKEVICH, E. M., 2003. Simple model of spiking neurons. *IEEE Trans Neural Netw*, **14**(6), 1569–1572. 93
- IZHIKEVICH, E. M., 2004. Which model to use for cortical spiking neurons? *IEEE Trans Neural Netw*, **15**(5), 1063–1070. ISSN 1045-9227. 93
- IZHIKEVICH, E. M., 2006. Polychronization: Computation with Spikes. *Neural Comput.*, **18**(2), 245–282. ISSN 0899-7667. 40, 93
- JAKOBI, N., 1998. *Minimal Simulations for Evolutionary Robotics*. Tesis Doctoral, COGS. 27, 29, 45, 46, 47, 48
- JAKOBI, N., HUSBANDS, P. Y HARVEY, I., 1995. Noise and the reality gap: the use of simulation in Evolutionary Robotics. En F. Moran, A. Moreno, J. Merelo y P. Chacon, eds., *Advances in Artificial Life. Proceedings of the III European Conference on Artificial Life ECAL95*. Springer, Berlin. 45
- K-TEAM, 1993. *Khepera users manual*. K-Team, Lausanne. 45, 52
- KANDEL, E. R., SCHWARTZ, J. Y JESSELL, T. M., 2000. *Principles of Neural Science*. Mc Graw Hill. 114
- KLIR, G. J. Y YUAN, B., 1995. *Fuzzy sets and fuzzy logic: theory and applications*. Prentice-Hall, Inc., Upper Saddle River, NJ, USA. ISBN 0-13-101171-5. 19
- KOHONEN, T., 1982. Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, **43**, 59–69. 20, 37
- KOHONEN, T., 1995. *Self-Organizing Maps*. Springer, Berlin. 20
- KOZA, J. R., 1992. *Genetic programming: on the programming of computers by means of natural selection*. MIT Press, Cambridge, MA. 27, 30, 42
- KWOK, H. F., JURICA, P., RAFFONE, A. Y VAN LEEUWEN, C., 2007. Robust emergence of small-world structure in networks of spiking neurons. *Cognitive Neurodynamics*, **1**(1), 39–51. 93
- LANGTON, C., TAYLOR, C., FARMER, J. D. Y RASMUSSEN, S., 1991. *Artificial Life II*. Addison Wesley, Redwood City, CA. 23
- LANGTON, C. G., ed., 1989. *Artificial Life: the proceedings of an interdisciplinary workshop on the synthesis and simulation of living systems*. Addison-Wesley, Redwood City, CA. Workshop held September, 1987 in Los Alamos, New Mexico. 6, 23
- LAZKANO ORTEGA, E., 2004. *Pautas para el desarrollo incremental de una arquitectura de control basada en el comportamiento para la navegación de robots en entornos semi-estructurados*. Tesis Doctoral, Universidad del País Vasco. 28, 43, 44
- LIEBENTHAL, E., BINDER, J. R., SPITZER, S. M., POSSING, E. T. Y MEDLER, D. A., 2005. Neural Substrates of Phonemic Perception. *Cereb. Cortex*, **15**(10), 1621–1631. URL <http://cercor.oxfordjournals.org/cgi/content/abstract/15/10/1621>. 38
- LUND, H. H., WEBB, B. Y HALLAM, J., 1997. A Robot Attracted to the Cricket Species *Gryllus bimaculatus*. En P. Husbands y I. Harvey, eds., *IV European Conference on Artificial Life ECAL97*, 246–255. MIT Press/Bradford Books, MA. 25, 36, 44, 45, 69, 90, 91
- MAASS, W., 1997. Networks of spiking neurons: the third generation of neural network models. *Neural Networks*, **10**, 1659–1671. 8, 37, 40

- MAASS, W., 1999. *Pulsed neural networks*. MIT Press, Cambridge, MA, USA. ISBN 0-626-13350-4. 3, 8, 40
- MACINNES, I. Y DI PAOLO, E. A., 2006. The advantages of evolving perceptual cues. *Adaptive Behavior*, **14**(2), 147 – 156. 47
- MATARIĆ, M. Y CLIFF, D., 1996. Challenges in Evolving Controllers for Physical Robots. *Evolutional Robotics, special issue of Robotics and Autonomous Systems*, **19**(1), 67–83. 30, 36, 38, 46
- MCCULLOCH, W. Y PITTS, W., 1943. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, **5**, 115–133. 16, 38
- MEYER, J.-A. Y WILSON, S. W., eds., 1991. *From Animals to Animats: Proceedings of the 1st International Conference on Simulation of Adaptive Behavior*. MIT Press, Cambridge, MA. Paris. 23
- MIGLINO, O., LUND, H. H. Y NOLFI, S., 1995. Evolving Mobile Robots in Simulated and Real Environments. *Artificial Life*, **2**(4), 417–434. 35, 45
- MINSKY, M. Y PAPERT, S., 1969. *Perceptrons*. Cambridge, MA: MIT Press. 18, 19
- MIRA, J., 2006. La Inteligencia Artificial como ciencia y como ingeniería. En S. Fernández-Caballero, Miguel Tomé, ed., *50 años de la Inteligencia Artificial*, 1–12. Universidad de Castilla-La Mancha. 21
- MORENO, A. Y GONZÁLEZ-NALDA, P., 1997. El significado de las simulaciones en las Ciencias de lo Artificial: el caso del Programa de Investigación de la Vida Artificial Fuerte. En *II Congreso de la Sociedad de Lógica, Metodología y Filosofía de la Ciencia en España*. 24
- NEBOT, P. Y CERVERA, E., 2006. La arquitectura Acromovi: Una arquitectura para tareas cooperativas de robots móviles. En A. Fernández-Caballero, M. Gracia Manzano, E. Alonso y S. Miguel Tomé, eds., *Una perspectiva de la Inteligencia Artificial en su 50 aniversario*, 365–376. Universidad de Castilla-La Mancha. 23
- NEWELL, A. Y SIMON, H., 1963. GPS, a program that simulates human thought. En E. Feigenbaum y J. Feldman, eds., *Computers and Thought*, 279–293. McGraw-Hill. 18
- NIEDER, A. Y KLUMP, G., 1999. Adjustable frequency selectivity of auditory forebrain neurons recorded in a freely moving songbird via radiotelemetry. *Hearing Research*, **127**, 41–54. 53, 55, 115, 133, 135
- NOLFI, S. Y FLOREANO, D., 2001. *Evolutionary Robotics. The Biology, Intelligence, and Technology of Self-organizing Machines*, Volumen 14 de *Connection Science*. MIT Press, Cambridge, MA. URL <http://mitpress.mit.edu/book-home.tcl?isbn=0262140705>. 2001 (2nd print), 2000 (1st print). 3, 29
- NOLFI, S., FLOREANO, D., MIGLINO, O. Y MONDADA, F., 1994. How to Evolve Autonomous Robots: Different Approaches in Evolutionary Robotics. En R. Brooks y P. Maes, eds., *Artificial Life IV Proceedings*, 190–197. MIT Press-Bradford Books, Cambridge, MA. 35
- NOLFI, S. Y PARISI, D., 1993. Auto-teaching: networks that develop their own teaching input. En J. Deneubourg, S. Goss, G. Nicolis, H. Bersini y R. Dagonnier, eds., *Proceedings of the Second European Conference on Artificial Life, ECAL93: Self Organization & Life: From simple rules to global complexity*. Université Libre de Bruxelles. 35
- NOLFI, S. Y PARISI, D., 1995. Evolving artificial neural networks that develop in time. En F. Morán, A. Moreno y J. Merelo, eds., *Proceedings of the third European conference on Artificial Life: ECAL'95*. Berlin. Springer-Verlag. 35

- ROMERO, T., 2007. *Algoritmos de Estimación de Distribuciones Aplicados a Problemas Combinatorios en Modelos Gráficos Probabilísticos*. Tesis Doctoral, Universidad del País Vasco. 57
- RUMELHART, D. E., MCCLELLAND, J. L. Y THE *PDP Research Group*, 1986. *Parallel distributed processing: explorations in the microstructure of cognition, vol. 1: foundations*. Computational Models of Cognition and Perception. MIT Press, Cambridge, MA, USA. ISBN 0-262-68053-X. 19
- RUSSELL, S. J. Y NORVIG, P., 1994. *Artificial Intelligence. A Modern Approach*. Prentice Hall, Englewood Cliffs, NJ. 15, 17, 22
- SALOMON, R., 1997. The evolution of different neuronal control structures for autonomous agents. *Robotics and Autonomous Systems*, **22**, 199–213. 42
- SALTHER, S., 1995. The Role of Natural Selection Theory in Understanding Evolutionary Systems. En *International Symposium on Evolutionary Systems, ISES'95*. 47
- SCUTT, T., 1994. The Five Neuron Trick: Using Classical Conditioning to Learn How to Seek Light. En D. Cliff, P. Husbands, J. Meyer y S. S.W. Wilson, eds., *From Animals to Animats III: SAB'94*, 364–370. MIT Press-Bradford Books, Cambridge, MA. 25
- SEARLE, J., 1980. Minds, brains, and programs. *Behavioral and Brain Sciences*, **3**(236), 417–424. 17, 18, 21, 25
- SHANNON, C. Y WEAVER, W., 1949. *The Mathematical Theory of Communication*. Urbana, Illinois: University of Illinois Press. 16, 125
- SIEGWART, R. Y NOURBAKHSI, I., 2004. *Introduction to Autonomous Mobile Robots*. Bradford Book, MIT Press. 4
- SIMS, K., 1994. Evolving 3D Morphology and Behavior by Competition. En R. Brooks y P. Maes, eds., *Artificial Life IV Proceedings*, 28–39. MIT Press-Bradford Books, Cambridge, MA. 45
- SKINNER, B. F., 1938. *The behavior of organisms: An experimental analysis*. New York: Appleton-Century. 24
- SUZUKI, M., 2007. *Enactive robot vision*. Tesis Doctoral, Lausanne. URL <http://library.epfl.ch/theses/?nr=3974>. 31, 32, 33, 44, 93, 94, 133
- SUZUKI, M. Y FLOREANO, D., 2006. Evolutionary Active Vision Toward Three Dimensional Landmark-Navigation. En *From Animals to Animats 9: The Ninth International Conference on the Simulation of Adaptive Behavior*, 263–273. URL http://dx.doi.org/10.1007/11840541_22. 25, 31, 48
- SUZUKI, M. Y FLOREANO, D., 2008. Enactive Robot Vision. *Adaptive Behavior*. 31
- TURING, A., 1950. Computing Machinery and Intelligence. *Mind*, **59**(236), 433–460. 16, 21, 25
- VOSE, M. D., WRIGHT, A. H. Y ROWE, J. E., 2003. Implicit Parallelism. En E. Cantu-Paz, ed., *Proceedings of GECCO 2003*, 1003–1014. Springer. 42
- WALTER, W., 1950. An imitation of life. *Scientific American*, **6**, 42–45. 24
- WALTER, W., 1951. A machine that learns. *Scientific American*, **6**, 60–63. 24
- WANG, L., TAN, K. C. Y CHEW, C. M., 2006. *Evolutionary robotics: from algorithms to implementations*, Volumen 28 de *Robotics and Intelligent Systems*. World Scientific. URL <http://www.worldscibooks.com/compsci/6164.html>. 27, 28, 42, 43, 44

- WEIZENBAUM, J., 1966. ELIZA—a computer program for the study of natural language communication between man and machine. *Commun. ACM*, **9**(1), 36–45. ISSN 0001-0782. [17](#)
- WIENER, N., 1948. *Cybernetics or Control and Communication in the Animal and the Machine*. Wiley and Sons, New York. [17](#), [24](#)
- YAMAUCHI, B. Y BEER, R., 1994. Integrating Reactive, Sequential, and Learning Behavior Using Dynamical Neural Networks. En D. Cliff, P. Husbands, J. Meyer y S. Wilson, eds., *From Animals to Animats III: SAB'94*, 382–391. MIT Press-Bradford Books, Cambridge, MA. [25](#), [35](#), [40](#)
- ZADEH, L. A., 1965. Fuzzy Sets. *Information and Control*, **8**(3), 338–353. [19](#)
- ZADEH, L. A., 1968. Fuzzy Algorithms. *Information and Control*, **12**(2), 94–102. [19](#)



Glosario

Autoorganización

Proceso por el que un sistema conexionista, formado por una red de elementos simples, aumenta en complejidad por la dinámica de sus partes, que normalmente da lugar a la aparición de una estructura emergente.

Página: [6](#), [23](#), [25](#), [27](#)

Complejidad

Concepto que indica la cantidad de interacciones que existen en un sistema formado por un conjunto de partes y que son interacciones necesarias para que el sistema sea entendido e identificado como tal. Un ordenador es un sistema complicado, un lápiz un sistema simple, y la sociedad es un sistema complejo. Una forma de medir la complejidad de un sistema es la medida de la cantidad de información necesaria para describirlo, según la Teoría de Shannon y Weaver (1949).

Página: [4](#), [47](#)

Conductismo

Corriente psicológica basada en el estudio del comportamiento a partir de relaciones causa-efecto, considerando el individuo estudiado como una *caja negra*.

Página: [58](#)

Conexionismo

Paradigma que usa el modelado de procesos mentales y del comportamiento como resultado de procesos emergentes a partir de la dinámica de redes de elementos simples.

Página: [4](#), [17](#), [19](#), [21](#), [93](#)

Corporeidad

En inglés *embodiment*, la característica de poseer un cuerpo y formar una unidad el cuerpo y el sistema de control de un ser biológico o un robot.

Página: 4, 5, 21–23, 92

Dualismo

En este trabajo se refiere al Dualismo cartesiano, que consiste en la separación entre mente y materia. Descartes considera dos entidades al cuerpo y las capacidades cognoscitivas, inmateriales y separadas de la materia.

Página: 22

Emergencia

Proceso de aparición de nuevas características en un sistema debido a la interacción de sus partes simples interconectadas. Dichas características no pueden predecirse a partir del comportamiento de sus partes.

Página: 4, 43, 47

Epistémico

Relativo al estudio sobre la naturaleza del conocimiento y las condiciones de su validez.

Página: 43, 44, 90, 91

Exteroceptivo

Relativo a la percepción de estímulos cuyo origen es exterior al cuerpo.

Página: 92, 93

Filogenético

Relativo al estudio del individuo desde un punto de vista evolutivo.

Página: 10, 11, 34, 92

Fonotaxia

Taxia en la que el estímulo es un sonido.

Página: 25, 68, 73, 81, 90, 97

GOF AI

Gold Old-Fashioned Artificial Intelligence, la IA pasada de moda. Se usa para indicar que se intenta aplicar la Inteligencia Artificial de forma inadecuada a ciertos problemas, como la Robótica Autónoma, al no tener en cuenta conceptos como la corporeidad y la ubicación.

Página: 21

Hebbiano

Relativo a Donald Hebb, y más concretamente al método de aprendizaje que describió, y que se realiza mediante el refuerzo de la conexión sináptica entre neuronas que se disparan en una cierta franja de tiempo.

Página: 11, 93

Interoceptivo

Estímulo sensorial que proviene de los sistemas digestivo, respiratorio o circulatorio.

Página: 29, 92, 93

Morfogénesis

Generación de la forma, desarrollo ontogenético de un individuo que da lugar a una forma física y a funcionalidades relacionadas con ella.

Página: 10, 29, 46, 47, 56, 57, 90, 92–94

Neurobiología

Disciplina que estudia las neuronas y su interconexión en estructuras en el Sistema Nervioso.

Página: 39, 92

Neurociencia Computacional

Disciplina que estudia con el uso de ordenadores las características de las neuronas y sus interacción.

Página: 17, 40

Neurociencias

Disciplina que estudia el Sistema Nervioso en general, que puede incluir su estructura, funciones, desarrollo, procesos cognitivos, farmacología, etc.

Página: 4, 6, 20, 25, 26, 29, 30, 39, 40, 90

Neuroetología

Estudio del comportamiento animal a través de los mecanismos neurológicos.

Página: 36, 90

Ontogenético

Ámbito del desarrollo en vida del individuo, de la expresión de sus genes y los mecanismos morfogenéticos.

Página: 9, 11, 37, 85, 93, 94

Paradigma

Prácticas que definen una disciplina científica en una cierta época.

Página: 21

Percolación

Transmisión de una perturbación a prácticamente todos los elementos de una red en un sistema conexionista. Que una perturbación *percole* depende de un cierto valor crítico de p , la probabilidad de que la perturbación se transmita de un elemento a su vecino. Unos ejemplos típicos son el fuego, los rumores y las enfermedades.

Página: 41

Propioceptivo

Percepción del movimiento y posición del cuerpo en el espacio y de la posición de unas partes del cuerpo respecto a otras.

Página: 31, 92, 93

Psicoacústica

Estudio de los mecanismos que intervienen en la percepción auditiva, tanto los fisiológicos como los psicológicos.

Página: 37

Reduccionismo

Método de explicación de fenómenos a través de su descomposición en partes más simples y la suposición de que la composición de dichos comportamientos no lleva a nuevas características.

Página: 6

Sensomotor

Lo referente a la conexión entre la parte sensorial y la motora de un organismo, y que forma un sistema dinámico junto con la interacción con el exterior del individuo.

Página: 18, 22

Sigmoidea

Función que produce una curva sigmoidea, como la arcotangente y la función logística. Crecen exponencialmente hasta la saturación. Matemáticamente, $\sigma(x) = 1/(1 + e^{-x})$

Página: 8, 31, 37–39, 55, 94

Subsimbólico

Que carece de símbolos establecidos y se basa en relaciones numéricas de las que emergen relaciones que son un símbolo en el contexto adecuado.

Página: 4, 19, 20

Taxia

Movimiento de un organismo libre y móvil como respuesta a un estímulo. Se denomina positiva si el movimiento es de acercamiento, y negativa en caso contrario.

Página: 10, 24, 29, 43

Tropismo

Movimiento de orientación de un organismo sésil (sujeto e inmóvil) como respuesta a un estímulo.

Página: 24

Ubicación

En inglés *situatedness*, tener un entorno determinado en un instante concreto. El propio entorno es el modelo que debe usar el agente, sin crear una estructura simbólica en su sistema.

Página: 4, 5, 11, 23, 92



Índice alfabético

- élite, 32, 41, 52, 56, 68
- Continuous Time Recurrent Neural Networks*, 38
- General Problem Solver*, véase Solucionador General de Problemas
- Khepera*, 25, 31, 35, 36, 45, 52
- Nouvelle AI*, 21
- Paradoja de Collier*, 47
- Pulsed Neural Networks*, 39
- Spiking Neural Networks*, 39
- backpropagation*, véase retropropagación
- bias, 38
- feed-forward*, 37
- feedback*, véase retroalimentación
- fitness function*, véase función de adecuación
- fitness landscape*, véase paisaje de adecuación
- fuzzy logic*, véase lógica difusa
- gap, 46
- physical grounding hypothesis*, véase hipótesis de la base física
- pruning*, véase poda
- symbol grounding problem*, véase problema de basarse en símbolos
- symbol system hypothesis*, véase hipótesis del sistema de símbolos
- ablación, 80
- acierto, 58, 94
- aprendizaje, 92
- autónomo, 24
- Autoorganización, 6, 23, 25, 28
- axón, 55, 83
- browniano, 43
- cóclea, 53, 111–113
- caja de Skinner, 24, 57
- capacidades cognitivas, 29
- cardioide, 53, 60, 64
- cognición, 29, 30
- Complejidad, 5, 48
- Conductismo, 58
- Conexionismo, 4, 17, 19, 21, 93
- corporeidad, 4, 6, 21, 23, 92, 93
- cruce, 41
- CTRNN, 38
- disparo, 55
- dualismo, 22
- EFA, 66, 94
- EFR, 66, 94

- ejecución, 65
 emergencia, 4, 43, 47
 entornos no estructurados, 21, 28, 90
 epistémico, 43, 44, 91, 92
 escalabilidad, 4, 11, 47
 espectro de frecuencias, 53
 espectro del control robótico, 4
 esquemas, 41
 evaluar comportamientos, 58
 experimento, 65
 exteroceptivo, 92, 93
 extracción de características, 7, 37, 39, 69, 89, 91

 fallo, 58, 94
 FC, 60
 FFT, 53, 59, 60, 73
 filogenético, 10, 11, 34
 fonotaxia, 25, 68, 73, 81, 90, 98
 fototaxia, 24
 frecuencia característica, 60
 frecuencia central, 53
 función de adecuación, 9, 32, 41, 46, 52, 58, 64, 94
 funcionalidad, 80
 funcionalismo, 18

 GOFAI, 21, 22, 29
 GPS, 18

 habitación china, 17, 18, 21
 hebbiano, 11, 93
 hipótesis de la base física, 21
 hipótesis del sistema de símbolos, 18–21

 innato, 11
 Inteligencia Computacional, 4, 20, 89
 interoceptivo, 29, 92, 93
 interpolación, 37

 lógica difusa, 19
 LISP, 18, 28, 41, 42

 mapa, 43
 metro, 58
 micrófono, 53
 morfogénesis, 10, 11, 29, 46, 47, 56, 57, 90, 92–94
 mutación, 41

 navegación, 31, 35, 42, 43, 51, 93

 Neurobiología, 39, 93
 Neurociencia Computacional, 17, 40
 Neurociencias, 4, 6, 20, 26, 29, 30, 39, 40, 90
 Neuroetología, 36, 90
 Nyquist, 108

 oído, 52
 odometría, 43
 ontogénico, 9, 11, 37, 85, 93, 94

 píxel, 31, 94
 paisaje de adecuación, 41–47
 paradigma, 21
 PCM, 59, 73
 PCNN, 39
 PDP, 19
 Percolación, 41
 poda, 80
 primitivas, 47
 problema de basarse en símbolos, 21
 problema de parada, 56
 propioceptivo, 32, 92, 93
 psicoacústica, 37
 pulso, 55
 puntos de referencia, 35, 43, 93
 puntuación, 66

 reconocimiento de patrones, 7
 Redes Bayesianas, 20
 reduccionista, 6
 retardo, 56, 83
 retroalimentación, 24
 retropropagación, 19–42
 Robótica Basada en el Comportamiento, 27
 ruido, 37, 69

 sacádico, 34
 sacada, 34
 semántica, 47
 Sensomotor, 18, 22
 sigmoidea, 8, 31, 37–39, 55, 94
 simulación mínima, 46
 Sistemas Dinámicos, 40
 Sistemas Expertos, 18
 SMPA, 22
 sobreconvergencia, 34, 92

Solucionador General de Problemas, 18

Subsimbólico, 4, 19, 20

taxia, 10, 24, 29, 43

templado estadístico, 20

test de Turing, 21

tics, 61

Transformada de Fourier, 52, 73

tropismo, 24

ubicación, 4, 6, 11, 23, 92

vehículos de Braitenberg, 24, 51, 53, 68, 73, 94

Vida Artificial, 4, 6, 8, 23–28, 37, 43, 89

visión, 31, 40



Índice de figuras

2.1. Vehículo de Braitenberg 2b.	25
3.1. Experimento planteado en el trabajo de Suzuki (2007).	32
3.2. Red Neuronal diseñada para el trabajo de Suzuki (2007).	33
3.3. Pulso generado a partir de la fórmula 3.8, con el que se simula burdamente el disparo de una neurona. A los tres primeros valores se les asigna el valor 0. Los valores son $\alpha = 1,666$ $\beta = 2,5\pi$ y $t = 0'1 \cdot \text{paso}/32$ s.	40
4.1. Proceso auditivo.	54
4.2. Espectro de frecuencias del canto de un pájaro. Tiempo en segundos (horizontal), frecuencia en Hz (vertical), y las mayores amplitudes de onda en amarillo (color claro).	54
4.3. Datos experimentales del umbral de activación para cada frecuencia, medidos con electrodos implantados en estorninos. La línea continua muestra el umbral de activación para cada frecuencia. La neurona reacciona de forma más intensa cuando la línea situada en el punto que relaciona su frecuencia y amplitud es larga (Nieder y Klump, 1999).	55
4.4. Estructura interna de un individuo. Conexiones a motores en rojo, axones en naranja (pesos positivos) y azul (negativos), y conexiones desde sensores en celeste y morado.	56
4.5. Pulso generado a partir de la fórmula 4.1, con el que se simula burdamente el disparo de una neurona. A los tres primeros valores se les asigna el valor 0. Los valores son $\alpha = 1,666$ $\beta = 2,5\pi$ y $t = 0'1 \cdot \text{paso}/32$ s.	62
5.1. Trayectorias espaciales de un robot resultante de la evolución, colocado en varios puntos de partida. El robot se acerca <i>instintivamente</i> al faro que emite el sonido A y evita el faro B.	65

5.2. Máximos y medias de los valores de la función de adecuación (eje Y) de los individuos de cada generación (eje X) en una ejecución del algoritmo genético.	66
5.3. Experimentos básicos que prueban la corrección del sistema, con dos histogramas por experimento, para EFA y EFR (superior e inferior, respectivamente). Los histogramas representan la cantidad de individuos que obtienen cada porcentaje de efectividad.	67
5.4. Histogramas para el experimento que usa ruido rosa y ruido blanco (en la izquierda), e histogramas del experimento con dos cantos de pájaro de la figura 5.5 (en la derecha).	69
5.5. El espectro de frecuencias de los sonidos (extraídos del canto de un canario) para el experimento preparado para probar el reconocimiento de una secuencia temporal. Tiempo en segundos (horizontal), frecuencia en Hz (vertical), y las mayores amplitudes de onda en amarillo.	70
5.6. Histogramas para el experimento con dos sonidos de fondo adicionales compuestos de batería y música rock.	71
5.7. Máximos y medias de los valores de la función de adecuación (eje Y) de los individuos de cada generación (eje X) en una ejecución del algoritmo genético para el experimento que tiene ruidos de fondo. Comparar con la figura 5.2.	71
5.8. Histogramas para el experimento hecho con <i>dos</i> fuentes adicionales de ruido blanco.	72
5.9. Histogramas para el experimento hecho con <i>cuatro</i> fuentes adicionales de ruido blanco.	72
5.10. Intensidad y espectro de frecuencias de los sonidos usados en el experimento con partes de silencio, que son una modificación de los de la figura 5.5.	74
5.11. Histogramas para el experimento con dos sonidos con partes de silencio.	75
5.12. Diagrama de la evolución de la puntuación máxima y media de la población en el experimento con dos sonidos con partes de silencio.	75
5.13. Histogramas para el experimento con dos sonidos con formato PCM.	76
5.14. Diagrama de la evolución de la puntuación máxima y media de la población en el experimento con sonidos de formato PCM.	76
6.1. El espectro de frecuencias de los sonidos usados en este experimento (ver sección 5.4), filtrados tal como lo hacen los sensores (frecuencias alrededor de los 2293 Hz y 1392 Hz), con dos diferentes intensidades de color en la representación de la intensidad con el objetivo de observar por una parte el ruido y por otra la intensidad de la señal que usa el individuo.	82
6.2. Estructura del individuo del análisis, antes y después de la <i>poda</i> . Los números grandes son el número de neurona, y los pequeños indican el retardo de las conexiones que llegan a esa neurona. El color naranja expresa que el peso es positivo, y el azul que es negativo. En el caso de los sensores, todos son positivos (color vino).	84
A.1. Gráficos de las coordenadas, distancias y ángulo analizados durante una prueba desde el punto de salida hasta llegar a la fuente correcta. Los valores x e y son las coordenadas absolutas, $d1$ la distancia al faro correcto y $d2$ al erróneo. El ángulo inicial de 180 indica que se dirige hacia la izquierda. Si se da un giro de 180 a la gráfica X-Y se obtiene la trayectoria real, en la que lo correcto es el giro hacia abajo o a la izquierda, ya que la coordenada Y crece hacia abajo.	98
A.2. Gráficos de valores de cada uno de los sensores analizados durante una prueba desde el punto de salida hasta llegar a la fuente correcta. El valor dB es la intensidad del sonido que entra al sensor y $activ$ es la respuesta de éste, que causa la salida s	99

A.3. Gráficos de valores de velocidad de disparo de la neurona (el valor d , cuanto más alto más rápidamente) y de la activación de los motores (m) durante una prueba desde el punto de salida hasta llegar a la fuente correcta.	100
A.4. Detalle en $t = 92600$ de las gráficas de la figura A.1.	101
A.5. Detalle en $t = 92600$ de las gráficas de la figura A.2.	102
A.6. Detalle en $t = 92600$ de las gráficas de la figura A.3.	103
A.7. Detalle en $t = 120000$ de las gráficas de la figura A.1.	104
A.8. Detalle en $t = 120000$ de las gráficas de la figura A.2.	105
A.9. Detalle en $t = 120000$ de las gráficas de la figura A.3.	106
B.1. Representación de partes del canto de un canario en espectro de frecuencias (tiempo en horizontal y frecuencia en vertical, intensidad del sonido más alta en amarillo). Un sensor obtendría su activación con una franja horizontal de este gráfico, con una máxima amplitud igual a la zona superior de la V . .	109
B.2. Activación de una neurona sensora de estornino para cada frecuencia y volumen del sonido. Figura de Nieder y Klump (1999)	115



Índice de tablas

- 6.1. Configuración de los sensores. Su separación a cada lado del eje es de 64° (grados sexagesimales). . . 81
- 6.2. Configuración y conectividad de las neuronas. Todas son efectoras y sólo la pareja 2–3 se conecta a ambos motores. Se puede observar que sólo se reescriben en las neuronas 2 y 3 los valores de las dendritas pares en la segunda vez que se expresa la información genética. 81



Índice general

Agradecimientos	VII
Índice general	IX
Resumen y organización de la memoria	XIII
Resumen	XIII
Organización	XIV
I Área de investigación y objetivos del trabajo	1
1 Análisis del área de investigación y objetivos del trabajo	3
1.1. Área de investigación: antecedentes y estado actual de la cuestión	4
1.2. Objetivos del trabajo	6
1.2.1. Obtención de un robot con un comportamiento de navegación en entornos no estructurados	7
1.2.2. Impulso de los objetivos técnicos de la Robótica Evolutiva	8
1.3. Problema implementado en la aplicación TOPOS	9
II Estado del Arte: Informática, Inteligencia Artificial y Robótica Evolutiva	13
2 De la Lógica a la Robótica Evolutiva	15
2.1. La Inteligencia Artificial y su relación con la Informática	15
2.2. Cerebros y máquinas	16
2.3. Conferencia de Dartmouth, Turing y Searle	16

2.4.	La época dorada de la Inteligencia Artificial	18
2.4.1.	Newell y Simon: la hipótesis del sistema de símbolos. El funcionalismo	18
2.4.2.	Sistemas Expertos	18
2.4.3.	Cierre de la vía de las Redes Neuronales	18
2.5.	Crisis y resurgimiento de la Inteligencia Artificial	19
2.6.	El Conexionismo	19
2.7.	La Robótica en la Inteligencia Artificial	20
2.8.	Problemas fundamentales de la IA en la Robótica	21
2.9.	La revolución robótica	22
2.9.1.	Rodney Brooks. Corporeidad y ubicación	22
2.9.2.	Inspiración biológica: la Robótica basada en la Vida Artificial	23
2.9.3.	La <i>Caja de Skinner</i> y el concepto de Autonomía en la Vida Artificial	24
2.9.4.	Walter y Braitenberg	24
2.9.5.	Robótica Evolutiva	25
3	Análisis de la Robótica Evolutiva	27
3.1.	Objetivos y motivaciones específicos de la Robótica Evolutiva	27
3.2.	Situación actual de la Robótica Evolutiva	29
3.3.	Grupos básicos en Robótica Evolutiva	30
3.3.1.	John Koza	30
3.3.2.	Francesco Mondada y Dario Floreano	31
3.3.3.	Mototaka Suzuki	31
3.3.3.1.	Experimento y Red Neuronal	31
3.3.3.2.	Resultados	33
3.3.4.	Inman Harvey, Phil Husbands, Dave Cliff y Nick Jakobi	34
3.3.5.	Adrian Thompson, Phil Husbands e Inman Harvey	34
3.3.6.	Stefano Nolfi y Domenico Parisi	35
3.3.7.	Randall Beer y Brian Yamauchi	35
3.3.8.	Applied AI Systems, Inc. (AAI), Ottawa, Canadá	36
3.3.9.	Henrik Hautop Lund, Barbara Webb y John Hallam	36
3.3.10.	Trabajo en castellano	36
3.4.	Redes Neuronales	37
3.4.1.	Descripción matemática de las Redes Neuronales	38
3.4.2.	<i>Continuous Time Recurrent Neural Networks</i> (CTRNN)	39
3.4.3.	Redes Neuronales de Pulsos	39
3.5.	Algoritmos Genéticos	41
3.6.	Algoritmos Genéticos con Redes Neuronales en la RE	42
3.7.	La navegación en la Robótica Evolutiva	43
3.8.	Objetivos de los modelos en la Robótica Evolutiva	44
3.9.	Simulaciones y realizaciones en Robótica Evolutiva	44
3.9.1.	Sólo simulación	45
3.9.2.	Simulación y comprobación de los resultados en robot real	45
3.9.3.	Evolución exclusivamente en robots reales	45
3.9.4.	Conclusiones	46
3.10.	Límites y problemas de la Robótica Evolutiva	46

3.10.1. La morfogénesis: evolución de la forma del robot	47
3.10.2. El problema de la <i>escalabilidad</i>	48
III La aplicación TOPOS: diseño, ejecuciones y análisis de resultados	49
4 Descripción de la simulación TOPOS	51
4.1. Diseño general del modelo	51
4.1.1. Fuentes de sonido o <i>faros</i>	52
4.1.2. Individuos o <i>topos</i>	52
4.1.2.1. Sensores	53
4.1.2.2. Red neuronal	55
4.1.3. Algoritmo genético	56
4.1.4. Experimento y función de adecuación (<i>fitness</i>)	57
4.1.5. Problemas del planteamiento incremental	57
4.1.6. Evaluación de los individuos en las pruebas	58
4.2. Descripción pormenorizada de los elementos del modelo	58
4.2.1. Mundo	58
4.2.2. Fuentes de sonido o <i>faros</i>	59
4.2.3. Los individuos o <i>topos</i>	60
4.2.3.1. Sensores	61
4.2.3.2. Red Neuronal: neuronas y axones	61
4.2.4. Pruebas	63
4.2.5. Algoritmo Genético	63
5 Ejecuciones y resultados	65
5.1. Experimentos que comprueban la corrección del sistema	66
5.2. Eficacia de TOPOS en el reconocimiento de señales	68
5.2.1. Reconocimiento de una determinada intensidad de señal	68
5.2.2. Reconocimiento de una determinada secuencia temporal	69
5.3. Robustez de los resultados frente al ruido	69
5.4. Sonidos con partes de silencio	73
5.5. Capacidad del sistema con sonidos PCM	73
6 Análisis de un individuo	79
6.1. Objetivo y dificultades	79
6.2. Proceso	80
IV Conclusiones y trabajo futuro	87
7 Resultados globales, conclusiones y trabajo futuro	89
7.1. Objetivos y resultados	89
7.1.1. Desarrollo técnico en la Robótica Evolutiva	90
7.1.2. Trabajo sobre algunos problemas de la Robótica Evolutiva	91
7.2. Conclusiones y trabajo futuro	92
7.2.1. Comparación con sistemas basados en visión	93

7.2.2. Otras ramas modernas de la Robótica	94
V Apéndices, bibliografía e índices	95
A Gráficas del análisis de un individuo	97
B El sonido y el oído. Psicoacústica	107
B.1. Naturaleza del sonido	107
B.2. Análisis de Fourier y espectro	108
B.3. Medida del nivel de sonido: dB	109
B.4. Linealidad	110
B.5. Filtros	110
B.6. Estructura y función básicas en el sistema auditivo	111
B.6.1. Oído externo y medio	111
B.6.2. Oído interno y membrana basilar	111
B.6.3. El proceso de transducción y las células ciliares	112
B.6.4. Respuesta del nervio auditivo	113
B.6.5. Umbrales y tasa de disparos espontáneos	113
B.6.6. Sincronización de fase (<i>Phase locking</i>)	113
B.6.7. Percepción del volumen	114
B.6.8. Percepción espacial: Cono de confusión y papel de los movimientos de la cabeza	114
B.6.9. Percepción espacial: Localización monoaural y la importancia del oído externo	114
B.7. Ejemplo de activación neuronal	115
Bibliografía	117
Glosario	125
Índice alfabético	129
Índice de figuras	133
Índice de tablas	137
Índice general	139